



# **Modelo de Previsão dos Consumos na RNT Considerando a Produção Distribuída**

**Rui Manuel Teixeira Carvalho**

Mestrado Integrado em Engenharia Eletrotécnica e de Computadores

Orientador: Prof. Doutor António Carlos Sepúlveda Machado e Moura

Co-orientador: Eng. Ricardo Vasco Fernandes

28 de Julho de 2015





A Dissertação intitulada

***“Modelo de Previsão dos Consumos na RNT Considerando a Produção Distribuída”***

foi aprovada em provas realizadas em 13-07-2015

o júri



Presidente **Professor Doutor José Rui da Rocha Pinto Ferreira**

Professor Auxiliar do Departamento de Engenharia Eletrotécnica e de Computadores  
da Faculdade de Engenharia da Universidade do Porto



**Professor Doutor Sérgio Augusto Pires Leitão**

Professor Auxiliar do Departamento de Engenharias da Escola de Ciências e  
Tecnologias da Universidade de Trás-os-Montes e Alto Douro



**Professor Doutor António Carlos Sepúlveda Machado e Moura**

Professor Catedrático do Departamento de Engenharia Eletrotécnica e de  
Computadores da Faculdade de Engenharia da Universidade do Porto

O autor declara que a presente dissertação (ou relatório de projeto) é da sua exclusiva autoria e foi escrita sem qualquer apoio externo não explicitamente autorizado. Os resultados, ideias, parágrafos, ou outros extratos tomados de ou inspirados em trabalhos de outros autores, e demais referências bibliográficas usadas, são corretamente citados.



**Autor - Rui Manuel Teixeira Carvalho**

Faculdade de Engenharia da Universidade do Porto



# Resumo

A constante mudança do Sistema Elétrico de Energia (SEE), devido à produção distribuída, faz surgir um novo modelo de exploração da Rede Nacional de Transporte (RNT).

O trânsito de potências passa a ter uma distribuição bidirecional nos transformadores das subestações da Rede Elétrica Nacional (REN), pelo que deixa de ser visto como o consumo real e passa a repartir-se em dois parâmetros: a carga natural e a soma de todos os produtores ligados a jusante da subestação.

Das funções do Gestor de Sistema (GS) da REN, salientam-se a garantia da alimentação ininterrupta dos consumos e a gestão das indisponibilidades dos elementos de rede, linhas e transformadores, mantendo as margens de reserva adequadas e com a qualidade de serviço que lhe é exigível. Deste modo, no âmbito da programação de indisponibilidades de transformadores de potência, o GS necessita de uma previsão de carga afinada e com baixo erro.

A previsão de carga natural assume um fator muito importante para o GS, surgindo assim a necessidade de criar um modelo para previsão de curto prazo da carga natural de forma a apoiar o GS na tomada de decisão.

Nesta dissertação realizou-se o estudo sobre a previsão de carga natural com base em Redes Neurais Artificiais (RNA), procurando obter o melhor modelo de previsão de carga natural. Para tal, compararam-se o desempenho dos algoritmos de treino Levenberg-Marquardt (LM) e Resilient Backpropagation (RPROP), estudaram-se as variáveis justificativas do diagrama de carga e determinaram-se o número de neurónios a utilizar na camada escondida da RNA que garantisse os melhores resultados. Focou-se ainda a atenção aos dias de feriado visto nestes dias a previsão de carga ser atípica.

Os resultados obtidos foram muito satisfatórios, permitindo alcançar previsões com elevado grau de precisão e baixo erro.

Para complementar o trabalho, foi desenvolvida uma ferramenta informática de apoio ao GS que permite obter a previsão de carga natural num horizonte de sete dias. Destaca-se assim a melhoria introduzida neste departamento da REN, e por conseguinte do SEN, que permitirá programar a indisponibilidade de elementos de rede de forma mais segura, evitando reconfigurações desnecessárias, pelo facto dos valores apresentados se aproximarem mais da carga real.

Palavras-Chave: previsão de carga a curto prazo, redes neuronais artificiais, Levenberg-Marquardt, Resilient Backpropagation, carga natural, produção distribuída, diagrama de carga, Rede Nacional de Transporte.



# Abstract

The constant change in the Electrical Power System (EPS), due to distributed generation, creates a new model of managing the Portuguese Transmission Grid.

Nowadays the power flow is bidirectional on the Portuguese Transmission System Operator's (TSO) substation transformers, which ceases to be seen as a real consumption and splits into two parameters: the Natural Load and the sum of all the producers connected downstream of the substation.

From the TSO's System Manager (SM) responsibilities, it emphasizes the uninterrupted power supply to consumers and outage planning, regarding power lines and transformers, keeping the adequate reserve margins and considering the required quality of service. Therefore when planning transformers outage, the SM needs a fine-tuned load forecast together with low error.

The natural load forecast assumes an important factor to the SM, emerging a need to create a model for short-term natural load forecasts in a way to help the SM in decision making.

In this dissertation a study was performed about natural load forecast based on Artificial Neural Networks (ANN), searching for the best natural load forecast model. Bearing this in mind, comparisons were made between the performance of the training algorithms Levenberg-Marquardt (LM) and Resilient Backpropagation (RPROP), the justifiable variables of the load diagram were studied and the number of neurons to be used on the hidden layer of the ANN was determined in order to guarantee the best results. The study of holidays was focused due to the fact that in those days load forecast is atypical. The results were very satisfactory, enabling to achieve forecasts with a high degree of precision and low error.

To complete this work, a computer tool was developed to provide support to the SM which performs a natural load forecast in a seven days scope.

It stands out the improvement provided to the TSO, and thereby the EPS as a whole, enabling the outage planning to be safer, avoiding unnecessary network reconfigurations, because load forecast approaches the actual load.

**Keywords:** short-term load forecast, artificial neural network, Levenberg-Marquardt, Resilient Backpropagation, natural load, distributed production, load diagram, Portuguese Transmission Grid.



# Agradecimentos

Após terminus de mais uma etapa da minha vida, revejo tudo que vivi até agora, se hoje sou o que sou, devo simplesmente a duas pessoas: - aos meus pais. Quero-lhes deixar aqui o meu eterno agradecimento por tudo o que me proporcionaram até hoje. À minha irmã Joana, por estar sempre presente e me aconselhar sempre da melhor forma, acalmando-me sempre nos momentos mais difíceis da minha vida. Não posso deixar também de agradecer a toda a minha família pela força que sempre me transmitiram e por acreditarem sempre em mim.

A alegria, apoio e motivação ao longo do desenvolvimento desta dissertação sempre estiveram presentes no meu orientador, Professor Doutor António Machado e Moura, a quem desde já quero agradecer por todo o apoio prestado.

Uma pessoa incansável, sempre pronta a ajudar e a esclarecer alguma dúvida que me surgisse, muita paciência e simpatia, quero deixar um FORTE agradecimento ao meu Co-orientador Eng. Ricardo Vasco Fernandes pelo tempo que predispôs para me orientar e pelos conselhos dados ao longo do desenvolvimento desta dissertação.

Ao Eng. Vieira Couto quero deixar também um agradecimento pelas excelentes condições de trabalho e pela experiência que me proporcionou. Aos restantes elementos do COR, que sempre estiveram predispostos a ajudar-me, um obrigado.

Também um agradecido obrigado ao Professor Nuno Fidalgo pela sua disponibilidade e atenção no esclarecimento de algumas dúvidas.

O que seria da vida sem amigos? A todos os meus amigos quero agradecer o apoio sentido, os sorrisos, as músicas, as festas, o estudo, os bons e maus momentos. . . Enfim, por tudo que nos foi proporcionado ao longo destes anos, porque sempre que precisei, vocês estiveram lá!

Rui Carvalho



*“The wisdom of men is not proportional to their experience, but to their ability to gain  
experience.”*

George Bernard Shaw





# Conteúdo

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Enquadramento e Motivação . . . . .	1
1.2	Objetivos . . . . .	2
1.3	Estrutura da dissertação . . . . .	3
<b>2</b>	<b>Rede Nacional de Transporte</b>	<b>5</b>
2.1	A RNT . . . . .	5
2.2	Gestor do Sistema - Operação de Rede . . . . .	8
2.2.1	Estrutura Organizacional da REN . . . . .	8
2.2.2	Centro de Operação da Rede . . . . .	10
<b>3</b>	<b>Redes Neurais Artificiais</b>	<b>11</b>
3.1	Introdução às Redes Neurais Artificiais . . . . .	11
3.2	Arquitetura das Redes Neurais Artificiais . . . . .	13
3.2.1	Estrutura de um neurónio . . . . .	14
3.2.2	Processos de Aprendizagem ou Treino . . . . .	17
<b>4</b>	<b>Variáveis Justificativas do Diagrama de Carga</b>	<b>21</b>
4.1	Subestações . . . . .	21
4.1.1	Caraterização das Subestações . . . . .	22
4.2	Previsões de Carga . . . . .	25
4.3	Diagrama de Carga . . . . .	25
4.3.1	Fatores que Influenciam o Diagrama de Carga . . . . .	26
<b>5</b>	<b>Metodologia de treino das RNA</b>	<b>35</b>
5.1	Escolha de Subestações Teste . . . . .	35
5.2	Metodologia de Trabalho . . . . .	35
5.2.1	Recolha de Dados . . . . .	36
5.2.2	Tratamento de Dados . . . . .	37
5.2.3	Treino da Rede Neuronal Artificial . . . . .	40
5.2.4	Análise do Desempenho da Rede . . . . .	47
<b>6</b>	<b>Resultados</b>	<b>49</b>
6.1	Comparação de Algoritmos - Teste A . . . . .	49
6.1.1	Comparação de Tempo Computacional . . . . .	51
6.1.2	Comparação de Precisão . . . . .	52
6.1.3	Comparação da Periodicidade das Variáveis de Entrada . . . . .	53
6.1.4	Comparação do Histórico de Dados . . . . .	54
6.1.5	Aspetos conclusivos do teste A . . . . .	55

6.2	Variável Temperatura - Teste B . . . . .	56
6.3	Variável Feriado - Teste C . . . . .	57
6.3.1	Teste C1 . . . . .	58
6.3.2	Teste C2 . . . . .	60
6.3.3	Comparação dos Testes C1 e C2 com Teste A . . . . .	62
6.4	Variável Feriado e Temperatura - Teste D . . . . .	62
6.5	Número de Neurónios a Utilizar - Teste E . . . . .	64
6.6	Resultados de outras subestações . . . . .	67
6.7	Comparação de Resultados com o Modelo de Previsão Desenvolvido . . . . .	67
6.7.1	Perceção do erro obtido . . . . .	70
<b>7</b>	<b>Conclusões e Trabalhos Futuros</b>	<b>71</b>
7.1	Conclusões . . . . .	71
7.2	Desenvolvimentos Futuros . . . . .	72
	<b>Referências</b>	<b>75</b>
<b>A</b>	<b>Aplicação - Previsão de Carga Natural</b>	<b>79</b>
A.1	Requisitos da Aplicação . . . . .	79
A.2	Comandos da Aplicação . . . . .	79
A.3	Manual de Utilização . . . . .	81
<b>B</b>	<b>Caraterização das Subestações</b>	<b>85</b>
B.1	Tipo de Consumo . . . . .	85
B.2	Sazonalidade . . . . .	86
<b>C</b>	<b>Comparação de Métodos</b>	<b>91</b>
<b>D</b>	<b>Mapa RNT</b>	<b>95</b>

# Lista de Figuras

2.1	Evolução do comprimento dos circuitos de linha em serviço na rede MAT e Potência de Transformação [1]	6
2.2	Evolução do número de subestações e postos de corte, seccionamento e transição da RNT	7
2.3	Comparação entre a potência eólica e a potência do SEN [2]	7
2.4	Evolução da Potência Instalada [2]	8
2.5	Organograma da unidade de negócio Eletricidade da REN	8
3.1	Neurónio humano [3]	12
3.2	Evolução cronológica das RNA [4]	12
3.3	Esquema de representação dos tipos de RNA e algoritmos de treino	13
3.4	Estrutura de um neurónio artificial [5]	14
3.5	Representação das funções de ativação mais utilizadas [6]	15
3.6	Estrutura de uma RNA do tipo MLP [7]	16
4.1	Diagrama de cargas para uma semana numa subestação da região do Algarve	22
4.2	Diagrama de cargas para uma semana numa subestação na região de Lisboa	22
4.3	Caraterização por sazonalidade	24
4.4	Caraterização por tipo de consumo	24
4.5	Gráfico que ilustra o tipo de sazonalidade por tipo de consumo	24
4.6	Diagrama de Carga diário do SEN para o dia 2 de Abril de 2014	26
4.7	Correlação entre CN e a CN da semana anterior à mesma hora para o período da Primavera	27
4.8	Correlação entre CN e a CN da semana anterior à mesma hora para o período do Outono	27
4.9	Correlação da CN com a CN de duas semanas anteriores à mesma hora para o período da Primavera	27
4.10	Correlação da CN com a CN de duas semanas anteriores à mesma hora para o período do Outono	27
4.11	Comparação do diagrama de carga semanal com o da semana anterior e duas semanas anteriores para o período de Inverno	28
4.12	Comparação do diagrama de carga semanal com o da semana anterior e duas semanas anteriores para o período de Primavera	28
4.13	Comparação do diagrama de carga semanal com o da semana anterior e duas semanas anteriores para o período de Verão	28
4.14	Comparação do diagrama de carga semanal com o da semana anterior e duas semanas anteriores para o período de Outono	29

4.15	Comparação do diagrama de carga da semana de 8 a 14 de Dezembro de 2014 com a semana anterior . . . . .	30
4.16	Comparação do diagrama de carga da semana que inclui o feriado de 25 abril 2013 com a semana anterior . . . . .	30
4.17	Comparação do diagrama de carga da época Natalícia com a semana anterior . . .	31
4.18	Comparação entre o diagrama de carga da semana de 9 a 15 de Junho de 2014 com a semana anterior . . . . .	31
4.19	Comparação do diagrama de carga diário feriado de 20 de Abril com o Domingo anterior . . . . .	31
4.20	Representação da temperatura média diária no ano 2014, para Portugal Continental e para a cidade de Lisboa . . . . .	32
4.21	Correlação entre valores de temperatura e carga CN para Portugal Continental . .	34
4.22	Correlação entre valores de temperatura e carga CN para cidade de Lisboa . . . .	34
4.23	Representação da correlação entre a CN por localidade e Portugal Continental com as respetivas temperaturas . . . . .	34
5.1	Metodologia global para elaboração de um modelo para previsão de CN . . . . .	36
5.2	Exemplo da folha Excel para tratamento de dados . . . . .	37
5.3	Apresentação dos vários testes efetuados . . . . .	41
5.4	Metodologia adotada para desenvolvimento do teste A . . . . .	42
5.5	Metodologia adotada para desenvolvimento do teste B . . . . .	43
5.6	Metodologia adotada para desenvolvimento do teste C . . . . .	43
5.7	Metodologia adotada para desenvolvimento do teste D . . . . .	44
5.8	Metodologia adotada para desenvolvimento do teste E . . . . .	45
6.1	Modelo da RNA utilizada para o teste A . . . . .	49
6.2	Gráfico referente à média do tempo de treino para entradas com periodicidade de 15 minutos . . . . .	51
6.3	Gráfico referente à média do tempo de treino para entradas com periodicidade de uma hora . . . . .	52
6.4	Gráfico de comparação do MAPE apresentado por cada algoritmo para um histórico de um ano e três anos, com entradas de periodicidade de 15 minutos . . . . .	52
6.5	Gráfico de comparação do MAPE apresentado por cada algoritmo para um histórico de um ano e dois anos, com entradas de periodicidade de uma hora . . . . .	53
6.6	Gráfico de comparação da periodicidade de entradas para um histórico de dados de um e três anos. . . . .	53
6.7	Gráfico de comparação do histórico de entradas a utilizar para o algoritmo LM . .	54
6.8	Gráfico de comparação do histórico de entradas a utilizar para o algoritmo LM . .	54
6.9	Gráfico de comparação do MAPE para os três testes efetuados para a subestação S34 . . . . .	55
6.10	Modelo da RNA referente ao teste B2 . . . . .	56
6.11	Gráfico de comparação do MAPE para os três testes efetuados . . . . .	57
6.12	Modelos da RNA referente ao teste C2 . . . . .	58
6.13	Gráfico de comparação entre a CN prevista no teste A, Teste C1 e CN real para S34 na semana de 28 de Abril a 4 de Maio de 2014 . . . . .	59
6.14	Gráfico de comparação entre a CN prevista no teste A, Teste C1 e CN real para S34 para o dia 10 de Junho de 2014 . . . . .	59
6.15	Gráfico de comparação entre a CN prevista no teste A, Teste C1 e CN real para S34 para o dia 15 de Dezembro de 2014 . . . . .	60

6.16	Gráfico de comparação entre a CN prevista no teste A, Teste C1, Teste C2 e CN real para S34 para o dia 10 de Junho de 2014 . . . . .	60
6.17	Gráfico de comparação entre a CN prevista no teste A, Teste C1, Teste C2 e CN real para S34 para o dia 15 de Dezembro de 2014 . . . . .	61
6.18	Gráfico de comparação entre a CN prevista no teste A, Teste C1, Teste C2 e CN real para S34 para o dia 25 de Abril de 2014 . . . . .	61
6.19	Gráfico de comparação entre a CN prevista no teste A, Teste C1, Teste C2 e CN real para S34 para o dia 8 de Dezembro de 2014 . . . . .	61
6.20	Gráfico de comparação do MAPE para os testes efetuados . . . . .	62
6.21	Modelo da RNA referente ao teste D2 . . . . .	63
6.22	Comparação do MAPE obtido para todos os testes realizados . . . . .	64
6.23	Comparação do MAPE para o modelo E2 e o modelo do COR para a semana de 20 de Abril a 26 de Abril de 2015 . . . . .	68
6.24	Diagrama de carga real e previsto para a semana de 20 de Abril a 26 de Abril de 2015 para a subestação S53 . . . . .	68
6.25	Diagrama de carga real e previsto para a semana de 20 de Abril a 26 de Abril de 2015 para a subestação S53 . . . . .	69
6.26	Diagrama de carga real e previsto para a semana de 27 de Abril a 3 de Maio de 2015, para a subestação S17 . . . . .	70
A.1	Interface gráfica da aplicação . . . . .	80
A.2	Tabela apresentada pelo botão 1 . . . . .	81
A.3	Ficheiro Excel aberto pelo botão 3 . . . . .	81
A.4	Temperaturas apresentadas após a seleção da capital de distrito desejada . . . . .	82
A.5	Janela aberta pelo botão 3 para seleção da subestação desejada . . . . .	82
A.6	Interface gráfico da aplicação após ser concluído o processo do botão 3 . . . . .	83
A.7	Apresentação do gráfico dos valores previstos para a subestação selecionada . . . . .	83
B.1	Gráfico de comparação do tipo de sazonalidade por tipo de consumo . . . . .	89
C.1	Diagrama de carga real e previsto para a semana de 20 de Abril a 26 de Abril de 2015 para a subestação S23 . . . . .	91
C.2	Diagrama de carga real e previsto para a semana de 20 de Abril a 26 de Abril de 2015 para a subestação S42 . . . . .	92
C.3	Diagrama de carga real e previsto para a semana de 20 de Abril a 26 de Abril de 2015 para a subestação S17 . . . . .	92
C.4	Diagrama de carga real e previsto para a semana de 27 de Abril a 3 de Maio de 2015, para a subestação S23 . . . . .	93
C.5	Diagrama de carga real e previsto para a semana de 27 de Abril a 3 de Maio de 2015, para a subestação S42 . . . . .	93
C.6	Diagrama de carga real e previsto para a semana de 27 de Abril a 3 de Maio de 2015, para a subestação S53 . . . . .	94
D.1	Mapa da RNT . . . . .	96



# Lista de Tabelas

4.1	Valores da correlação entre a CN e a CN da semana anterior e de duas semanas anteriores por período . . . . .	27
4.2	Valores da correlação entre a CN e a CN S1H1, S1H2, S2H1 e S2H2 por período . . . . .	29
5.1	Representação das possíveis candidatas a variáveis de entrada da RNA, com periodicidade de 15 em 15 min . . . . .	38
5.2	Representação das possíveis candidatas a variáveis de entrada da RNA, com periodicidade de uma hora . . . . .	39
5.3	Representação das possíveis candidatas a variáveis de entrada da RNA, com periodicidade de 15 em 15 min após normalização . . . . .	40
6.1	Média dos resultados obtidos por subestação com entradas de periodicidade de 15 minutos, com o algoritmo RPROP . . . . .	50
6.2	Média dos resultados obtidos por subestação com entradas de periodicidade de 15 minutos, com o algoritmo LM . . . . .	50
6.3	Média dos resultados obtidos por subestação com entradas de periodicidade de uma hora, com o algoritmo RPROP . . . . .	50
6.4	Média dos resultados obtidos por subestação com entradas de periodicidade de uma hora, com o algoritmo LM . . . . .	51
6.5	Apresentação do valor máximo, mínimo e médio anual de CN para os anos 2012, 2013 e 2014 . . . . .	55
6.6	Comparação de erros entre os 3 testes efetuados para a subestação S34 . . . . .	55
6.7	Comparação de erros entre testes . . . . .	57
6.8	Comparação de erros obtidos entre os testes C1 e C2 . . . . .	62
6.9	Comparação de erros obtidos para teste D1 e D2 . . . . .	63
6.10	Resultados dos erros obtidos do teste E1 e E2 na primeira fase para as subestações S22, S34 e S45 . . . . .	64
6.11	Resultados dos erros obtidos do teste E1 e E2 na segunda fase para as subestações S1, S17, S22, S34, S40 e S45 . . . . .	65
6.12	Identificação do número de neurónios e teste com menor erro por subestação . . . . .	66
6.13	Número de neurónios da camada escondida que apresentaram menor erro para os dias selecionados . . . . .	66
6.14	Resultados obtidos com a aplicação do modelo E2 para outras subestações . . . . .	67
6.15	Resultados obtidos pelo modelo do teste E2 e o modelo de previsão do COR, para a semana de 20 de Abril a 26 de Abril de 2015 . . . . .	68
6.16	Comparação do MAPE para o modelo E2 e o modelo do COR para a semana de 27 de Abril a 3 de Maio de 2015 . . . . .	69
B.1	Padronização do fator de carga por tipo de consumo . . . . .	86

B.2	Padronização do fator de carga sazonal . . . . .	87
B.3	Caraterização das subestações . . . . .	89



# Abreviaturas e Símbolos

AT	Alta Tensão
BP	Backpropagation
COR	Centro de Operação da Rede
ERSE	Entidade Reguladora dos Serviços Energéticos
GS	Gestor do Sistema
GSOR	Departamento de Operação da Rede da direção do Gestor do Sistema
IPMA	Instituto Português do Mar e da Atmosfera
LM	Levenberg-Marquardt
MAT	Muito Alta Tensão
MLP	Multilayer Perceptron
PD	Produção Distribuída
PdE	Pontos de Entrega
PRE	Produção em Regime Especial
PRO	Produção em Regime Ordinário
REN	Rede Eléctrica Nacional
RNA	Rede Neuronal Artificial
RNT	Rede Nacional de Transporte
RPROP	Resilient backpropagation
RQS	Relatório da Qualidade de Serviço
SCADA	Supervisory Control and Data Acquisition
SEE	Sistema Eléctrico de Energia
SEN	Sistema Eléctrico Nacional
TCD	Taxa Combinada de Disponibilidade
MW	Unidade de Potência ativa
kV	Unidade de Tensão



# Capítulo 1

## Introdução

O presente documento foi desenvolvido no âmbito da unidade curricular Dissertação do Mestrado Integrado em Engenharia Eletrotécnica da Faculdade de Engenharia da Universidade do Porto. Esta dissertação aborda o tema do modelo de previsão dos consumos da Rede Nacional de Transporte (RNT) considerando a Produção Distribuída (PD) em que se procede à análise de vários casos de estudo. Neste capítulo é apresentado o enquadramento geral do tema abordado, a motivação e objetivos intrínsecos ao desenvolvimento da dissertação. É também apresentada, no final do capítulo, a estrutura da dissertação.

### 1.1 Enquadramento e Motivação

Em Portugal, a entidade responsável pelo transporte de eletricidade é a REN – Redes Energéticas Nacionais, sendo esta a concessionária da RNT. Esta concessão implica que a REN seja responsável pelo planeamento, construção, operação e manutenção da RNT, abrangendo ainda o planeamento e a gestão técnica global do Sistema Elétrico Nacional [8].

O Gestor de Sistema (GS) deve assim assegurar de forma ininterrupta os equilíbrios necessários ao desempenho técnico do sistema elétrico a nível nacional, garantindo a qualidade de serviço, em condições de segurança e sempre com as convenientes margens de reserva [9].

A RNT tem o objetivo de ligar os produtores aos centros de consumo, e ainda a interligação necessária com a rede de transporte europeia, para garantir o funcionamento dos mercados de eletricidade. Para além das centrais térmicas e hídricas clássicas de grande dimensão, têm surgido muitas outras de menor potência, no âmbito da produção de origem renovável ou da cogeração. Assim, os diagramas de carga das subestações da RNT na fronteira com a rede de distribuição sofreram nos últimos anos uma profunda modificação. Esta deve-se ao crescente número de Produtores Distribuídos presentes nas redes de distribuição, em especial devido aos produtores eólicos, que apresentam um carácter volátil na produção de energia.

Atualmente, a PD totaliza valores muito significativos, por vezes até superiores aos do consumo de uma subestação, aumentando a incerteza na previsão das cargas do ponto de vista do transporte. Devido a esta incerteza surgiu a necessidade da concepção de um modelo, que utiliza

técnicas de previsão baseadas em inteligência artificial, para previsão dos consumos nos Pontos de Entrega (PdE) da RNT, de modo a auxiliar o GS na tomada de decisão relativamente às solicitações de indisponibilidades de transformadores de potência ou linhas da RNT, sem colocar em risco os consumos garantindo sempre as margens de reserva adequadas.

No GS está disponível um modelo de previsão de carga de curto prazo baseada em Redes Neurais Artificiais (RNA). Contudo, esta apresenta algumas limitações:

- A aprendizagem das RNA requer um tempo de computação muito elevado;
- Não contempla na estrutura da RNA, a possibilidade de indicação da ocorrência de situações anómalas nos dados considerados para a previsão;
- O erro da previsão tem alguma margem de redução;
- Método moroso para o tratamento de dados provenientes de fontes diferentes.

Tomando como ponto de partida as limitações que o modelo de previsão utilizada pelo GS apresenta, surge a motivação para a realização desta dissertação.

## 1.2 Objetivos

Nas subestações MAT/AT o trânsito de potências dos transformadores não corresponde à real carga elétrica por eles alimentados. Para isso é necessário separar em duas componentes, a de carga e a de produção distribuída nas redes a jusante. O valor efetivo do consumo de uma subestação, designado doravante por Carga Natural (CN), resulta da soma algébrica do trânsito nos transformadores com o da geração distribuída a jusante. Isto é, no caso de uma falha local da produção distribuída, a CN é aquela que deve ser fornecida pela RNT para alimentação dos consumos.

No âmbito da sua atividade, o GS necessita da previsão a curto prazo da CN para cada subestação da REN. Conforme foi referido, esta é realizada através de um modelo de previsão de apoio ao GS para auxiliar as suas decisões, tendo sido objeto de estudo em [7].

O objetivo desta dissertação é melhorar esse modelo. Para a obtenção de um melhor desempenho, é necessário delinear um conjunto de objetivos específicos, que entre outros, tem como base o estudo das RNA.

1. Caracterização das subestações da REN, considerando o tipo de consumo e a sua localização geográfica;
2. Melhoria da extração e tratamento de dados relativos às cargas naturais por subestação e dos valores meteorológicos;
3. Aquilatar a adequação da ferramenta de previsão atual à dinâmica do Sistema Elétrico Nacional;
4. Estudo de algoritmos de treino de Redes Neurais alternativos que permitam um treino mais célere;

5. Definir uma estrutura de RNA que permita reduzir o erro global e incluir situações anômalas nos dados considerados para a previsão;
6. Desenvolvimento da aplicação de apoio ao GS para a tomada de decisão;
7. Justificar e provar as várias etapas da metodologia;
8. Escrita da dissertação.

### 1.3 Estrutura da dissertação

Para permitir uma melhor compreensão das metodologias utilizadas e estudos efetuados para obtenção dos objetivos propostos, a presente dissertação tem uma lógica sequencial, apresentada em 7 capítulos.

No capítulo 1 é feito o enquadramento do tema, é apresentada a motivação que levou à realização desta dissertação e são traçados os objetivos para a mesma.

O capítulo 2 apresenta a descrição e evolução da RNT, focando também as funções da sua concessionária, a REN, evidenciando a sua estrutura funcional e o enquadramento do GS.

No capítulo 3 é estudada a técnica de previsão de carga a curto prazo utilizada nesta dissertação, baseada em séries temporais – as RNA. É efetuado um estudo referente aos vários tipos de redes neuronais e métodos de aprendizagem, dando especial atenção aos vários tipos de algoritmos que podem ser utilizados.

No capítulo 4 as subestações pertencentes à REN são analisadas, nomeadamente no que diz respeito ao tipo de consumo por estas alimentado e a sua localização geográfica. São abordados também neste capítulo os fatores que influenciam o diagrama de carga, sendo apresentado o resultado do estudo efetuado sobre as variáveis justificativas do diagrama de carga.

O capítulo 5 apresenta a metodologia para o desenvolvimento deste estudo. Sendo apresentadas as várias etapas adotadas para ser possível alcançar o modelo final de uma RNA para previsão de CN a curto prazo.

O capítulo 6 expõe a comparação de resultados entre os diferentes algoritmos e número de entradas aplicados ao treino das RNA e a aplicação do mesmo às várias subestações da REN. No final deste capítulo é apresentada uma comparação entre o modelo desenvolvido ao longo desta dissertação e o atual do GS.

As conclusões obtidas nesta dissertação e trabalhos futuros são apresentados no capítulo 7. Neste destacam-se os pontos fortes e as dificuldades encontradas ao longo do desenvolvimento deste trabalho, assim como possíveis desenvolvimentos futuros, que não estando no âmbito da presente dissertação, possam aprimorar a metodologia e a aplicação desenvolvida.



## Capítulo 2

# Rede Nacional de Transporte

A REN possui a concessão exclusiva da Rede Nacional de Transporte, de acordo com o artigo nº69 do Decreto-Lei 29/2006 [10].

A RNT assegura a ligação da energia elétrica produzida nas centrais eletroprodutoras até às redes de distribuição, ligando posteriormente aos consumidores finais, existindo algumas exceções em que os consumidores estão ligados a RNT, por questões técnicas ou económicas [11].

Neste capítulo, será apresentado uma breve descrição da RNT para enquadramento do tema, assim como uma análise da estrutura e funções desempenhadas pela concessionária da RNT.

### 2.1 A RNT

A atividade do transporte de energia elétrica integra o desenvolvimento, a exploração e a manutenção da RNT, as suas interligações com outras redes e a gestão técnica global do sistema, assegurando a coordenação das instalações de produção e distribuição, de modo a garantir a continuidade e segurança do abastecimento e funcionamento integrado e eficiente do sistema, sendo a REN a entidade responsável por todas estas funções [12].

A rede de transporte apresenta uma topologia emmalhada, está dividida em três níveis de tensão 400 kV, 220 kV e 150 kV e a interligação a Espanha é efetuada em nove pontos, sendo seis interligações a 400 kV e três a 220 kV. Atualmente é constituída por 63 subestações, 10 postos de corte, 2 de seccionamento, 1 de transição e um conjunto de linhas de transporte que totalizava no ano de 2014, 8630 km, sendo estas quase exclusivamente aéreas, nos níveis de tensão 400 kV, 220 kV e 150 kV. Os troços em cabo subterrâneo são explorados a 220 kV e 150 kV, nomeadamente na região da Grande Lisboa e Grande Porto [11] [13]. Relativamente à compensação do fator de potência, a RNT possui baterias de condensadores e reatâncias *shunt*. Para limitação das correntes de defeito, encontram-se ao serviço na RNT diversas reatâncias de fase e de neutro [13]. No anexo D é possível visualizar a disposição da RNT a nível nacional.

Em termos globais observa-se na figura 2.1 uma tendência para o aumento das linhas de 400 kV e de 220 kV e uma pequena redução de 150 kV. Isto deve-se à desclassificação e “*upgrade*” de alguns circuitos de RNT em fim de vida útil a este nível de tensão. A reconfiguração da RNT tem

privilegiado níveis de tensão mais elevados devido às vantagens que estes apresentam de eficiência energética e a nível ambiental, pois apresentam maior capacidade de transporte e perdas menores [14].




Figura 2.1: Evolução do comprimento dos circuitos de linha em serviço na rede MAT e Potência de Transformação [1]

O número de subestações e de postos de corte aumentaram também nos últimos anos, devido essencialmente a três fatores:

- Reforço da capacidade de receção devido à construção de novos centros produtores;
- Reforço da alimentação dos consumos através da Rede de Distribuição;
- Critérios de segurança e planeamento da rede.

Assim na figura 2.2 é possível verificar o aumento significativo do número de subestações e postos de corte para os níveis de tensão de 400 kV e 220 kV, mantendo o mesmo número para o nível de 150 kV.

Para um melhor desempenho da RNT, a Entidade Reguladora dos Serviços Energético (ERSE) considera um mecanismo de incentivo, o aumento da disponibilidade dos elementos da RNT, sendo um fator determinante para a qualidade de serviço, promovendo uma maior fiabilidade da rede de transporte.

Este mecanismo incide sobre o indicador Taxa Combinada de Disponibilidade (TCD), que conjuga os dois principais elementos da RNT, os circuitos de linha (linhas aéreas e subterrâneas) e os transformadores de potência (transformadores de entrega à rede de distribuição e os autotransformadores). No ano de 2014 a TCD foi de 98,9%, apresentando o melhor valor de sempre, distanciando-se do valor de referência da ERSE de 97,5%, sendo indicativo de uma contínua e progressiva melhoria da coordenação dos trabalhos efetuados [13] [15].

A continuidade de serviço caracteriza e avalia as situações em que se verifica a interrupção do fornecimento de energia elétrica aos PdE. Esta é avaliada em indicadores de qualidade de serviço






Figura 2.2: Evolução do número de subestações e postos de corte, seccionamento e transição da RNT

gerais que se referem à totalidade de um sistema ou zona geográfica, e indicadores individuais que se referem a cada um dos pontos de entrega.

A REN anualmente procede à caracterização da onda de tensão, em conformidade com um plano de monitorização, realizado para o efeito de medições nos PdE. As características da onda de tensão nos PdE aos clientes MAT e AT devem respeitar os limites estabelecidos no Relatório da Qualidade de Serviço (RQS).

Em Portugal existem dois regimes de produção, denominados por Produção em Regime Ordinarário (PRO) e Produção em Regime Especial (PRE). A PRO tem como base de produção as fontes tradicionais não renováveis e grandes centros eletroprodutores hídricos, a PRE é caracterizada pela sua produção a partir da utilização de fontes de energia renováveis, processos de cogeração e microprodução (produção de eletricidade em muito pequena escala, com uma potência instalada inferior a 5.75kW) [16].

Nas figuras 2.4 e 2.3 é possível verificar um crescimento considerável da PRE, nomeadamente um aumento da produção eólica, onde existe quase um quarto da produção de fonte eólica. Com a evolução das fontes renováveis foi criado um novo paradigma no “mix” de produção elétrica nacional, devido ao aumento do número de parques eólicos, sendo esta fonte de energia uma das mais promissoras.

Potência Eólica / Potência SEN			
	2012	2011	2010
[MW]			
SEN	18 546	18 894	17 895
Eólica	4 194	4 080	3 706
	23%	22%	21%

Figura 2.3: Comparação entre a potência eólica e a potência do SEN [2]




Figura 2.4: Evolução da Potência Instalada [2]

## 2.2 Gestor do Sistema - Operação de Rede

### 2.2.1 Estrutura Organizacional da REN

A presente dissertação foi realizada em ambiente empresarial, na REN, no departamento de Operação da Rede da Divisão do Gestor do Sistema (GSOR), que está sediado em Vermoim. Na figura 2.5 é representado a estrutura organizacional da REN.

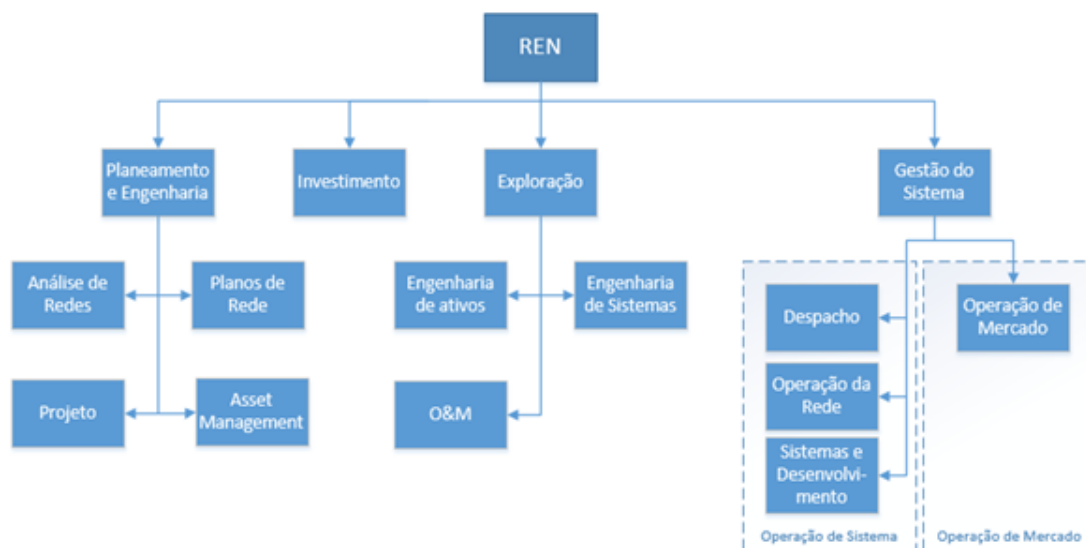


Figura 2.5: Organigrama da unidade de negócio Eletricidade da REN

- **Planeamento e Engenharia**

Esta Direção tem como missão planear e coordenar a elaboração e definição das estratégias das soluções de evolução da RNT e dos planos que as englobam, assegurando ainda o controlo das análises e soluções da rede, a nível local e global, no sentido de garantir que o desempenho da RNT está de acordo com as necessidades do SEN, mantendo igualmente, no seu horizonte, a preocupação de reduzir impactos ambientais globais à escala da AAE do PDIRT [17].

- **Investimento**

Esta Direção tem como missão coordenar e controlar a execução dos projetos e das obras constantes do Plano de Desenvolvimento e Investimento da RNT, garantindo a concretização e entrada em funcionamento das infraestruturas elétricas nos prazos e custos definidos [17].

- **Exploração**

Esta Direção tem como função coordenar e controlar a manutenção operacional de todos os ativos materiais das subestações e linhas que constituem a RNT, de modo a garantir a integridade da RNT e a qualidade de serviço prestado [17].

- **Gestão do Sistema**

O GS tem como missão assegurar o bom funcionamento do SEN, de acordo com a legislação vigente, estratégia e políticas definidas, no sentido de garantir a segurança da RNT e da interligação à rede continental europeia, bem como o equilíbrio entre a produção e o consumo, otimizando o SEN no âmbito das suas competências [17].

A Direção GS subdivide-se em quatro departamentos, Despacho, Sistemas e Desenvolvimento, Operação de Mercado e Operação de Rede. O GS tem como principais responsabilidades [18]:

- Monitorizar a rede em tempo real através do sistema SCADA/EMS, identificando situações anómalas e coordenando o restabelecimento do serviço após incidente;
- Assegurar a verificação técnica da operação do sistema elétrico, conjugando os programas de produção e consumo dos agentes de mercado com a constituição de reservas;
- Garantir permanentemente o equilíbrio entre a geração e o consumo de eletricidade, mobilizando ou desmobilizando geração que foi objeto de mercado, por forma a evitar desvios e a garantir o abastecimento e a segurança do sistema;
- Monitorizar, controlar e operar remotamente a RNT, coordenando a segurança das manobras em regime normal e reagindo a incidentes que ameacem a estabilidade e o regular funcionamento da rede;
- Gerir os sistemas de informação de suporte à atividade de Gestão do sistema, garantindo a fiabilidade e segurança da operação e adaptando-os à evolução das suas necessidades.

### 2.2.2 Centro de Operação da Rede

O Centro de Operação da Rede (COR) insere-se no departamento de Operação da Rede. Este tem como missão monitorizar, controlar e operar remotamente a RNT, coordenando a segurança das manobras em regime normal e reagindo a incidentes que ameacem a estabilidade e o regular funcionamento da rede [17] [19].

Para realização da missão referida anteriormente, o COR tem de [19]:

- Monitorizar permanentemente a RNT e reagir às perturbações na sua topologia ou nas grandezas: - tensão, corrente, frequência e temperatura, realizando as manobras necessárias para reposição das condições de operação normal.
- Monitorizar permanentemente os equipamentos das instalações da REN, realizando diagnósticos de avarias, estabelecendo graus de gravidade e notificando os agentes necessários para as resolver.
- Em regime normal, executar por telecomando as manobras necessárias nas instalações da REN, efetuando as comunicações necessárias para assegurar a coordenação com as salas de comando das entidades externas e com equipas de operação local;
- Participar em processos de criação de condições de segurança para trabalhos na RNT, assumindo o papel de Responsável e efetuando a emissão/receção das Autorizações de Trabalho.
- Atuar como centro de comunicações, assegurando a troca de informações sobre as redes com os diversos interlocutores internos e externos;
- Efetuar, no curto prazo, a análise básica dos incidentes na RNT, desencadeando de imediato ações corretivas quando necessário. Recolher e arquivar todas as informações disponíveis sobre os incidentes.
- Participar na programação de trabalhos que impliquem Indisponibilidades, Regimes Especiais de Exploração, Regimes de Intervenção em Serviço, ou Ensaios de colocação em tensão/serviço em instalações da RNT. Participar na elaboração do plano anual de indisponibilidades.
- Determinar os parâmetros a implementar nos equipamentos das instalações mais diretamente relacionados com a Operação e mantê-los atualizados e acessíveis.
- Promover a elaboração e atualização de Protocolos de Operação/Exploração relativos a todas as entidades externas que ligam à RNT.

## Capítulo 3

# Redes Neurais Artificiais

No presente capítulo é abordado o tema Redes Neurais Artificiais (RNA), onde é descrito o seu funcionamento de forma detalhada: as suas estruturas, os seus tipos de aprendizagem, assim como os seus algoritmos e modos de treino.

A previsão de carga a curto prazo é um tema muito abordado, pois desempenha um papel muito importante no setor elétrico [20] [21].

Através de vários estudos realizados, verifica-se que as redes neuronais apresentam um bom desempenho para previsão de carga a curto prazo, e em comparação com os métodos tradicionais, séries de regressão linear ou múltipla, apresentam melhores resultados. As redes neuronais são também menos exigentes a nível de tempo de computação em comparação com outras técnicas de previsão nomeadamente ARIMA, GARCH e Wavelet-ARIMA [20][21][6][22]. Devido a esta eficácia muitos tipos de RNA foram criadas, distinguindo-se cada uma delas pela sua estrutura e técnicas de treino aplicadas [23].

### 3.1 Introdução às Redes Neurais Artificiais

As Redes Neurais Artificiais são um modelo computacional constituído por unidades elementares denominadas por neurónios. Estas têm a capacidade de resolver uma gama de problemas de grande complexidade com uma técnica não linear. Assemelham-se ao comportamento do cérebro humano, baseando-se assim nos princípios da biologia, mais concretamente nos neurónios do sistema nervoso.

Todo o nosso organismo é constituído por uma rede de comunicação que forma o sistema nervoso, tendo este como unidade básica o neurónio, tendo este a constituição apresentada na figura 3.1. Cada neurónio tem a capacidade de detetar, transmitir, analisar e utilizar as informações geradas por estímulos e transformá-los numa resposta [4].

As dendrites captam os sinais eletroquímicos, passando-os ao corpo celular. A informação é processada, avançando ao longo da constituição do neurónio, até atingir os terminais pré-sinápticos, que assim passam a informação para outros neurónios. Isto ocorre por intermediação

química, que ativará dendrites de outros neurónios. Deste modo se passa a informação entre neurónios humanos [3].




Figura 3.1: Neurónio humano [3]

De uma forma análoga, as RNA, aplicam modelos matemáticos computacionalmente de forma a adquirir conhecimento através da experiência, isto é, retêm informação a partir da relação entre as entradas e saídas, ocorrendo um processamento interno não linear em cada neurónio. Na atualidade, as RNA apresentam grande capacidade e eficácia em aplicações que requerem inteligência artificial para obtenção de previsões. As RNA são consideradas “caixas negras”, pois é de difícil interpretação qual a relação que existe entre cada variável de entrada e saída [23] [5].

As primeiras aplicações das RNA ocorreram na década de 1930 na área da neurociência. Já no campo da engenharia estas foram utilizadas para controlo e reconhecimento na década de 1950. Na área da previsão somente na década de 1980 surgiram as primeiras aplicações nesta área [4]. A figura 3.2 sintetiza estas informações de forma esquemática e cronológica, e ainda outras datas relevantes. É possível verificar que houve um grande desenvolvimento na segunda metade do século XX, em parte fruto da evolução tecnológica. Assim, até a atualidade, tentam-se desenvolver técnicas mais aprimoradas e eficazes para as RNA, nomeadamente através de modificações efetuadas aos algoritmos de treino.



Figura 3.2: Evolução cronológica das RNA [4]

## 3.2 Arquitetura das Redes Neurais Artificiais

A organização e as ligações dos neurónios constituintes das RNA definem a arquitetura ou topologia da rede neuronal, decompondo-se em dois tipos, as unidirecionais (*feedforward*) e as recorrentes (*Recurrent ou feedback*).

As denominadas por unidirecionais, são redes onde as ligações formadas entre os neurónios têm uma única direção, ou seja a informação é propagada desde os neurónios de entrada até aos neurónios de saída sem que haja ciclos ou *loops* na rede. Nas redes unidirecionais normalmente os neurónios estão organizados por camadas, surgindo assim as redes *Multilayer Perceptron* (MLP), redes com várias camadas ou um tipo mais simples denominadas por *Single-Layer Perceptron* [6]. Este foi o primeiro e o mais simples tipo de RNA, sendo por norma as mais utilizadas.

As RNA recorrentes caracterizam-se por conter ligações entre neurónios no sentido progressivo e regressivo. Devido a esta possibilidade, têm o poder de processar a informação com recurso a “memória” interna, existindo realimentação. As saídas de um neurónio podem então ser entradas de um neurónio da camada seguinte ou da camada anterior, sendo que a taxa de alteração do estado interno pode ser alterada pelos pesos de recorrência, o que permite uma melhor perceção das distorções das entradas [24] [7].

No diagrama da figura 3.3 apresentam-se os tipos de redes neuronais assim como os seus algoritmos de treino, *Backpropagation* (BP), *Resilient Backpropagation* (RPROP) e *Levenberg-Marquardt* (LM). É possível constatar que é dado maior enfoque às redes unidirecionais do tipo MLP, pois serão o tipo de redes utilizadas na presente dissertação.

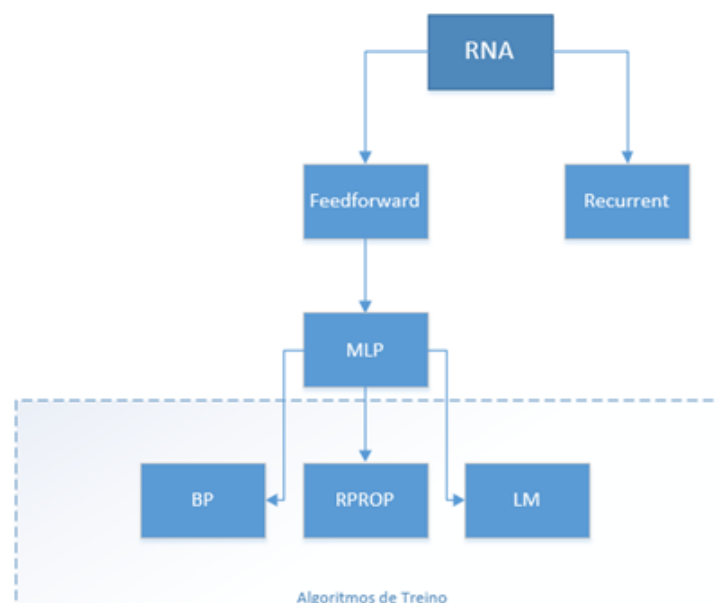


Figura 3.3: Esquema de representação dos tipos de RNA e algoritmos de treino

### 3.2.1 Estrutura de um neurónio

Os neurónios são as unidades básicas de processamento, que quando ligados entre si e organizados por camadas formam uma RNA. A partir das suas variáveis de entrada cada neurónio realiza um conjunto de operações, como é identificado na figura 3.4, sendo estas descritas detalhadamente de seguida.




Figura 3.4: Estrutura de um neurónio artificial [5]

Na expressão 3.1 é efetuada a soma ponderada de todas as variáveis de entrada multiplicada pelos seus pesos  $w_{ki}$ . Ou seja, isto traduz-se no somatório das multiplicações efetuadas entre os sinais emitidos pelas entradas ou por um neurónio da camada anterior, com o seu peso de ligação entre o neurónio  $K_x$  da camada anterior e o neurónio K.

$$\sum_{i=1}^n w_{ki} \times x_i \quad (3.1)$$

Após este passo, é somada a polarização (*bias*, segundo a literatura anglo-saxónica),  $b_k$ . Este parâmetro é considerado como um peso da RNA, correspondente ao peso da ligação entre a variável de entrada unitária e o neurónio k, como demonstra a expressão 3.2.

$$S_k = \sum_{i=1}^n w_{ki} \times x_i + b_k \quad (3.2)$$

A saída do neurónio  $y_k$ , é dada por  $f(S_k)$  isto é  $S_k$  vai ser aplicado na função de ativação e assim se obtém a saída do neurónio k, como apresentado na expressão 3.3.

$$y_k = f(S_k) \quad (3.3)$$

Os pesos,  $w_{ki}$  são valores que apresentam o grau de importância que determinada entrada



possui em relação àquele neurónio. O fator  $b_k$  corresponde ao limiar de ativação da resposta do neurónio. Quando  $b_k > 0$  apresenta um deslocamento para a direita da função de ativação, obrigando que a acumulação de sinais de entrada ultrapasse um certo limiar para originar uma resposta significativa do neurónio. O fator de polarização é considerado como mais um peso cujo valor também deverá ser determinando no decurso do treino. No fundo, é assumido que 1 é o sinal de uma entrada suplementar com um peso  $b_k$  a determinar [25].

Caso esta saída seja de uma camada intermédia, estes  $y_k$  são as entradas para os neurónios da camada seguinte ou seja  $y_k$  seriam um dos  $x_i$  para o neurónio da próxima camada e assim sucessivamente ao longo das várias camadas.

### 3.2.1.1 Função de Ativação

A função de ativação define matematicamente a relação entre as entradas e saídas de um neurónio. Para a aplicação nas redes neuronais é importante que a função de ativação introduza a não linearidade ou a capacidade de modelar uma função não linear [23].

A normalização da amplitude de saída do neurónio é realizada pela função de ativação, ou seja, realiza a transformação de uma grandeza com um domínio de valores no intervalo  $\mathbb{R}$  para um domínio de valores finito [7].

Em [23] é referido que as condições gerais para uma função contínua se qualificar como função de ativação, deve aumentar monotonamente, ser limitada e diferenciável. Assim sendo, as funções utilizadas são: - a função sigmoide, a função tangente hiperbólica, a função seno ou cosseno e a função linear. Nas RNA do tipo MLP é tipicamente utilizada a função não linear do tipo sigmoide para os neurónios das camadas escondidas e a função linear pura para os neurónios da camada de saída [5]. Na figura 3.5, são apresentadas as funções mais utilizadas no MLP.




Figura 3.5: Representação das funções de ativação mais utilizadas [6]

### 3.2.1.2 Multilayer Perceptron

Como já referido esta é uma estrutura de RNA do tipo unidirecional, em que os neurónios são organizados em camadas: uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída [26] [6]. Na figura 3.6 é possível visualizar um exemplo de rede MLP apenas com uma camada escondida com três neurónios, duas entradas e uma saída.

Normalmente os neurónios da camada de entrada servem para transferir o padrão de entrada ao resto da rede, ocorrendo processamento de informação apenas nas camadas escondidas e na camada de saída. Com exceção da camada de entrada, os sinais recebidos pelos neurónios vindos da camada anterior são ponderados pelos valores de interligação entre os neurónios [26] [27].

Cada camada possui vários neurónios e cada neurónio de cada camada é ligado aos neurónios da camada seguinte. Quando surge informação na camada de entrada esta passa posteriormente através das camadas escondidas até chegar à saída, e a cada ligação entre os neurónios é associado um peso [27].




Figura 3.6: Estrutura de uma RNA do tipo MLP [7]

### 3.2.1.3 Estrutura de uma MLP

A estrutura topológica de uma rede MLP é de extrema importância. Uma rede muito complexa pode levar a um aumento do ruído provocando a incapacidade de obtenção de resultados válidos. Contrariamente uma rede muito simples pode resultar numa inaptidão para reproduzir adequadamente os dados, sendo a rede incapaz de modelar dados mais complexos. Assim surge uma necessidade de se encontrar um equilíbrio entre a complexidade e simplicidade, de modo a que a rede seja capaz de fornecer dados credíveis [28].

A sua complexidade ou simplicidade referida anteriormente, depende-se com o número de unidades de entrada e saída, do número de camadas escondidas e do número de neurónios constituintes das camadas escondidas. Surgindo assim a questão de qual o número certo para obter a melhor estrutura de uma MLP [28].

Na verdade, não há nenhum estudo matemático que refira uma resposta definitiva para estas questões relativamente ao número de camadas escondidas e de neurónios de cada camada escondida. No entanto, em [5] são referidas técnicas baseadas em pressupostos heurísticos que propõem ultrapassar o problema de definição da estrutura de uma RNA. Outra possibilidade para superar este problema consiste num processo de tentativa/erro. Assim, através de testes efetuados é possível selecionar a estrutura que obtém um melhor desempenho [5].

Se for utilizado um número suficiente de neurónios escondidos, com apenas uma camada escondida, é possível aproximar-se uma RNA a uma função contínua [5].

O número de neurónios da camada escondida é encontrado através de um valor de compromisso, sem que haja risco de incapacidade ou generalização da aproximação da função pretendida [5].

### 3.2.2 Processos de Aprendizagem ou Treino

A propriedade mais importante da RNA é a capacidade de aprender autonomamente, de modo a que seja apresentado um ótimo desempenho. Através de um processo iterativo é realizado o ajuste dos seus pesos, ocorre um processo de adaptação ao comportamento e conduz a melhoria do desempenho, ou seja, o treino da rede. A aprendizagem ocorre, ou o treino está finalizado, quando a RNA atinge uma solução generalizada para uma classe de problemas.

Então o treino da RNA resume-se ao ajuste dos parâmetros livres da rede através de um mecanismo de apresentação de sinais ambientais, conhecidos como padrões ou dados de entrada, atingindo o seu objetivo quando é obtido um modelo implícito do sistema em estudo, por ajuste dos parâmetros da rede. Isto é conseguido a partir de um conjunto de regras denominado por algoritmo de treino. Surgem assim vários métodos de aprendizagem para as RNA, distinguindo-se três: supervisionada, não-supervisionada e forçada [29].

**Aprendizagem supervisionada:** este tipo de treino baseia-se num conjunto de dados de entrada e saída, ou em algum outro tipo de informação que represente o comportamento que deve ser apresentado pela rede neuronal, ou seja um agente externo indica à rede a resposta desejada para o padrão de entrada [29].

**Aprendizagem não supervisionada:** nesta aprendizagem não existe indicação da resposta desejada, ou seja apenas são dados à rede sinais de entrada à RNA [29].

**Aprendizagem forçada:** Neste treino existe uma avaliação da resposta fornecida pela rede pois são fornecidas as saídas correspondentes às entradas, deste modo são atribuídos prémios ou penalizações dependendo do desempenho [29].

Com base nestes três principais tipos de treino, desenvolveram-se outros tipos com o objetivo de os melhorar. Seguidamente são apresentados alguns deles.

**Aprendizagem pelo método de Perceptrão** - foi o primeiro treino supervisionado, sendo esta aprendizagem realizada por funções discretas, pois a função de transferência das unidades computacionais das redes perceptrões não é diferenciável [7] [29].

**Método do Gradiente** - neste método o seu algoritmo é capaz de resolver equações diferenciais, a cada iteração este método escolhe a direção que corresponde à descida mais íngreme da

função erro [7].

**Aprendizagem pelo método de Hebb** - este método possui um algoritmo que se enquadra na aprendizagem forçada. Este método propõe que as mudanças nos pesos das ligações entre neurónios sejam dadas pelo produto da atividade pré-sináptica e pós-sináptica [29].

**Aprendizagem competitiva ou de Kohonen** - este método de aprendizagem insere-se na classe dos algoritmos de aprendizagem não supervisionada. Neste método o direito à resposta é competido por todas as unidades de processamento [29].

**Aprendizagem por retropropagação** - denominado por *Backpropagation* na literatura anglo-saxónica, é o método de aprendizagem supervisionada mais utilizado. A partir de um conjunto pré-definido de dados de entrada/saída a rede aprende em ciclos de propagação. Dado um conjunto de entrada, o estímulo é propagado até à saída, assim os dados de saída são comparados com a saída desejada e é calculado um sinal de erro para cada elemento de saída. O sinal de erro é retropropagado ao longo das várias camadas, os elementos de cada camada intermédia apenas recebem uma porção do sinal de erro total, sendo proporcional à sua contribuição na formação da saída original. Os pesos das conexões são atualizados para cada neurónio baseados no sinal de erro recebido [30].

Na aprendizagem por retropropagação é possível a aplicação de vários algoritmos de treino. É dado de seguida especial atenção aos algoritmos de treino deste tipo de aprendizagem.

Após pesquisa bibliográfica para desenvolvimento da presente dissertação, dos diversos métodos e derivações encontrados para aplicação da aprendizagem por retropropagação é possível verificar-se a eficácia dos algoritmos de treino Levenberg-Marquardt e Resilient Backpropagation.

### ***Levenberg-Marquardt***

O algoritmo *Levenberg-Marquardt* supera o BP e muitos outros métodos de gradiente conjugado numa vasta variedade de problemas. Além disso, tem uma convergência e um treino de uma RNA mais rápida face ao BP [31] [32]. Este algoritmo é extremamente útil quando é necessário um treino muito preciso.

O LM é uma mistura de propriedades de pesquisa local de *Gauss-Newton* com um algoritmo de gradiente descendente, que proporciona uma descida de erro consistente. Este tipo de treino é considerado um problema de otimização sem restrições [31].

A principal desvantagem deste algoritmo é a elevada exigência de memória computacional para o cálculo da matriz Jacobiana da função de erro, com dimensões iguais ao número de pesos. Outra desvantagem é que nem sempre garante uma otimização global para um problema de otimização sem restrições [31].

### ***Resilient Backpropagation***

O algoritmo *Resilient Backpropagation* tem sido utilizado com sucesso no treino de RNA, onde foi provado que ganha vantagem sobre o típico procedimento de aprendizagem de gradiente descendente em vários problemas de referência [31].

O algoritmo RPROP proporciona um tempo de treino e ritmo de convergência mais rápido e possui a capacidade de escapar dos mínimos locais [32]. Apesar de haver um grande número de parâmetros ajustáveis no RPROP, a maioria desses parâmetros pode ser definida com valores por defeito. As pequenas variações em qualquer desses parâmetros não afetam o tempo de convergência [32].

O RPROP é um esquema de treino eficiente, que executa uma adaptação direta dos fatores de ponderação com base em informações de gradiente local. O princípio do RPROP é eliminar os efeitos prejudiciais das grandezas das derivadas parciais para calcular o peso [32].

É um algoritmo de primeira ordem, o tempo e memória necessária é linearmente proporcional ao número de parâmetros a otimizar, sendo este o algoritmo mais fácil de ajustar à regra de aprendizagem [32].

A taxa de aprendizagem pode limitar ou ampliar a extensão de ajuste de peso num ciclo de treino [31].

Este algoritmo aproveita os sinais do gradiente, de modo a aumentar a taxa de aprendizagem em casos onde gradientes consecutivos são do mesmo sinal, no entanto baixa a taxa de aprendizagem quando os sinais do gradiente vão alternando, sendo que o algoritmo identifica quando dois sinais consecutivos do gradiente estão a variar [31].

Apenas o sinal da derivada é utilizado para determinar a direção da atualização do peso, a magnitude da derivada não tem efeito na atualização do peso [31].

O valor de atualização para cada peso e *bias* é incrementado por um fator sempre que a derivada da função de desempenho que diz respeito a esse peso tem o mesmo sinal durante duas iterações. Será então decrementado caso o sinal mude após uma iteração. Se o valor da derivada for zero o valor de atualização mantém-se igual [31].

#### **3.2.2.1 Modos de Treino por Retropropagação**

O treino por retropropagação pode ser efetuado de três modos, tendo em consideração o propósito da previsão, a sua aplicabilidade prática e a precisão desejada para os resultados. Além disso, não são desprezáveis os recursos computacionais disponíveis. Assim, os modos são descritos sucintamente [25]:

**Modo *Batch ou Offline***, a atualização dos pesos é realizada apenas no fim de uma “época” ou de um conjunto de “épocas”. Depende do número máximo de iterações ou do valor do erro parametrizados.

**Modo Sequencial ou estocástico**, quando surge um novo exemplo do conjunto de treino da RNA ao algoritmo de treino é realizada uma atualização dos pesos. O erro é retropropagado para todos os pesos da rede neuronal quando o erro entre a saída e o valor desejado é calculado para cada exemplo de treino, assim tem-se o número de atualizações dos pesos igual ao número de exemplos do conjunto de treino.

**Modo *Online***, chama-se de treino *Online* ao funcionamento sequencial em tempo real. Neste tipo de treino, quando ocorre a chegada de um novo exemplo de treino, este é propagado desde a entrada até à saída da rede. O erro à saída será retropropagado apenas uma vez, atualizando de imediato os pesos da rede.

Os três modos de treino apresentam as suas vantagens e desvantagens. O treino *Online* para um melhor funcionamento requer um treino *offline* para determinar os pesos iniciais do treino. Este modo de treino apresentou resultados satisfatórios na previsão de carga de um sistema elétrico em estudos já realizados. Com o treino *Batch* é possível estimar o gradiente com grande rigor, garantindo pelo menos uma convergência para um mínimo local. Já o treino sequencial não apresenta garantia de convergência para um ótimo local. Isto deve-se ao seu caráter estocástico, o que evita ficar “preso” em ótimos locais. Ao nível de esforço computacional, requer um menor esforço.

## Capítulo 4

# Variáveis Justificativas do Diagrama de Carga

Cada subestação possui características únicas. No presente capítulo é efetuada uma caracterização das subestações da REN. O diagrama de carga é fortemente influenciado por fatores económicos, cronológicos, meteorológicos, demográficos e sociais. Assim, neste capítulo, é apresentado o estudo efetuado sobre as variáveis justificativas do mesmo.

### 4.1 Subestações

Com a entrada da PRE na produção, surgiu uma decomposição do trânsito efetivo nos transformadores de potência MAT/AT, tendo em conta a produção a jusante e a montante da posição do transformador. Deste modo o trânsito presente nos transformadores das subestações da RNT não corresponde à carga real.

Como já referido no capítulo 1, de modo a ultrapassar este problema surgiu assim o conceito de Carga Natural, que é obtida conforme a expressão 4.1. Pode-se então definir CN como sendo a soma do trânsito efetivo dos transformadores de potência das subestações e o total da produção distribuída ligada aquela subestação.

$$CN = TR + Prod(RND) \quad (4.1)$$

A figura 4.1 mostra a análise do trânsito de potência e CN na semana de 9 de Fevereiro de 2015 a 15 de Fevereiro de 2015 numa subestação da região do Algarve. Esta subestação apresenta uma forte ligação de PRE predominantemente eólica. Assim é possível explicar a discrepância que existe entre a CN e o trânsito de potências, pois a diferença entre os dois representa exatamente a PRE recebida pela referida subestação.




Figura 4.1: Diagrama de cargas para uma semana numa subestação da região do Algarve




Figura 4.2: Diagrama de cargas para uma semana numa subestação na região de Lisboa

Os gráficos das figuras 4.1 e 4.2 refletem o impacto da PRE no trânsito de potência nos transformadores presentes nas duas subestações. A diferença entre a CN e a trânsito de potências é a PRE, na subestação indicada na figura 4.1 existe uma maior predominância de PRE face à indicada na figura 4.2.

#### 4.1.1 Caracterização das Subestações

A atual dependência dos consumidores no que diz respeito à energia elétrica e ao aumento de exigência em questões de qualidade e continuidade de serviço, a RNT tem vindo ao longo dos últimos anos a sofrer diversas mudanças, tendo como objetivo adaptar-se às exigências atuais.

Assim cada subestação apresenta características únicas, dependendo do contexto em que está inserida, tornando-se útil para o operador de sistema saber qual o comportamento apresentado por cada subestação em diversas situações, de forma a poder ter uma atuação rápida. O conhecimento dos perfis de cada subestação é também útil para a previsão dos trânsitos de potência.



De modo a caracterizar o perfil de cada subestação, procurou-se definir o tipo de consumo associado. Esta análise encontra-se no anexo B para uma informação rápida sobre o perfil de cada subestação.

Em relação ao tipo de consumo, centrou-se o estudo em:

- Valores do consumo

Estudar os valores máximos, médios e mínimos de consumo associado a cada subestação, tendo em conta a estação do ano.

- Sazonalidade

Depreende-se como sazonalidade o facto de determinada estação do ano apresentar um determinado valor de CN ao longo de um período definindo entre as quatro estações do ano.

A classificação teve em conta uma metodologia apresentada no anexo B, a qual classifica as subestações em:

- Sem sazonalidade, isto é a CN é praticamente igual ao longo do ano independentemente das estações do ano.
- Sazonalidade moderada, a CN apresenta durante determinada estação do ano uma certa carga mais elevada ou mais baixa face às restantes estações do ano.
- Sazonalidade forte, apresenta duas estações do ano com diferentes valores de CN.

A metodologia adotada foca-se na dispersão entre a CN máxima e a CN média de cada estação do ano, resultando na classificação dos valores obtidos associados à classificação descrita. Para comprovação dos resultados obtidos foi feita uma análise dos diagramas de carga mensais de cada subestação.

- Tipo de consumo

A caracterização por tipo de consumo seguiu uma metodologia apresentada no anexo B, centrando-se na classificação do fator carga. Esta classificação foi reforçada pela análise dos diagramas de pontas anuais fornecidos pelo SCADA e pela análise dos esquemas da rede de distribuição de forma a verificar os consumos que cada subestação alimentava.

A classificação por tipo de consumo classifica as subestações por:

- Rurais
- Urbanas/Setor Terciário
- Industrial

Na figura 4.3 e 4.4 apresenta-se os valores globais dos resultados obtidos por esta caracterização.

Das 63 subestações disponíveis em Portugal Continental, 34 são Urbanas/Setor Terciário, 21 industriais e 8 rurais. Nota-se que apenas 5% das subestações não apresentaram sazonalidade, o




Figura 4.3: Caraterização por sazonalidade




Figura 4.4: Caraterização por tipo de consumo

que faz com que seja possível indicar que a temperatura altera o diagrama de carga, sendo que cada estação do ano é caraterizada tipicamente pelo seu grau de precipitação e temperatura.

Como indica o gráfico da figura 4.5, as subestações rurais, à exceção de uma, são de sazonalidade forte. Nas Urbanas/Setor Terciário predomina também a sazonalidade forte. Já nas subestações industriais predomina a sazonalidade moderada.




Figura 4.5: Gráfico que ilustra o tipo de sazonalidade por tipo de consumo

## 4.2 Previsões de Carga

Para o gestor de sistema, a previsão da carga natural é um ponto fulcral. Através da previsão o GS pode ter uma noção do que se irá passar no futuro. Deste modo a eficiência das diversas tomadas de decisão por parte dos operadores pode melhorar consideravelmente. Assim torna-se imprescindível para a gestão de energia, programação de indisponibilidades dos transformadores de potência e transferências de carga. Como já referido a REN tem o objetivo de manter o elevado padrão dos índices de qualidade de serviço, de modo a não se expor a situações de risco, a previsão de carga é então uma mais-valia.

A previsão de carga pode ser feita a curto, médio ou longo prazo, sendo que a previsão a curto prazo (*short-term load forecast*) é a indicada para previsão do diagrama diário para os próximos dias [33].

Dada a grande importância que a previsão de carga apresenta para o GS, ao longo dos últimos anos, diversos estudos têm sido efetuados de forma a melhorar as técnicas de previsão. Existe uma grande diversidade de técnicas para a previsão de carga a curto prazo, como os modelos tradicionais ou seja os métodos regressivos, métodos estocásticos e não lineares como modelos *Fuzzy* e Redes Neurais Artificiais.

As RNA são o modelo escolhido para previsão de carga na presente dissertação, sendo estas objeto de estudo no capítulo 3. Este método foi o modelo proposto pela REN, e com a pesquisa efetuada foi possível perceber que diversos estudos revelam este método eficaz para previsão de carga a curto prazo, mostrando melhores resultados face aos modelos tradicionais [33] [34] [22].

## 4.3 Diagrama de Carga

O diagrama de carga é representado através de uma função que é imposta através da modelação da energia consumida no tempo. A partir deste diagrama o GS consegue obter informação acerca da evolução dos consumos assim como perceber o tipo de consumo, sazonalidade e frequência [35].

As características do consumo modelam o diagrama de carga, através da figura 4.6 é possível verificar o padrão que este segue ao longo das 24 horas diárias, podendo assim ser classificado em 3 períodos:

- Período de vazio, que é fundamentalmente as horas do período noturno, apresentando um consumo mais baixo, representado por a iluminação pública e uma percentagem residual do setor de transportes e a algumas indústrias que funcionem neste período.
- Período de cheias, este começa por volta das 8 horas onde há um aumento do consumo que pode ser explicado pelo início das rotinas diárias de trabalho, entrando em funcionamento dos setores industrial, transporte e serviços.
- Período de ponta, que é associado ao período entre as 19 horas e as 22 horas, onde existe um pico no consumo refletido pelo consumo doméstico.




Figura 4.6: Diagrama de Carga diário do SEN para o dia 2 de Abril de 2014

#### 4.3.1 Fatores que Influenciam o Diagrama de Carga

O consumo é fortemente influenciado por certos fatores: económicos, cronológicos, meteorológicos, demográficos e sociais[33]. Sendo que o consumo está implícito na modelação do diagrama de carga estes fatores influenciam também o diagrama de carga, assim fez-se uma análise de algumas variáveis, de forma a perceber se são justificativas ou não do diagrama de carga, através da correlação entre as mesmas.

A sazonalidade possui uma forte influência no diagrama de carga, para isso correlaciona-se variáveis, em diferentes períodos do ano de forma a perceber qual a influência de cada uma das variáveis em estudo.

A divisão dos períodos foi feita tendo em conta as estações do ano pois os fatores meteorológicos também afetam o diagrama, sendo definidos da seguinte forma:

- **Período Inverno**, semana de 16 de Fevereiro de 2014 a 22 de Fevereiro de 2014;
- **Período Primavera**, semana de 12 de Maio de 2014 a 18 de Maio de 2014;
- **Período Verão**, semana de 21 de Julho de 2014 a 27 de Julho de 2014;
- **Período Outono**, semana de 13 de Outubro de 2014 a 19 de Outubro de 2014.

Os fatores cronológicos são também muito influenciadores no diagrama de carga, de modo a perceber qual a influência fez-se atrasos na CN de modo a perceber a sua influência.

#### 4.3.1.1 Correlação entre CN de uma e duas semanas anteriores a cada período

De forma a perceber qual a influência das semanas anteriores para o período em estudo, correlacionou-se a CN natural em cada período com uma (S1) e duas semanas (S2) de atraso á mesma hora.

Verifica-se nas figuras 4.7 e 4.8, assim como na tabela 4.1 uma forte correlação entre as variáveis para todos os períodos para ambos os atrasos efetuados á CN, à exceção da figura 4.9, este facto surge devido ao atraso de duas semanas contemplar um feriado, o 1 de Maio, existindo assim uma maior dispersão ao longo desta semana. Tendo em conta estes resultados obtidos é possível classificarmos estas variáveis como variáveis justificativas do diagrama de carga.




Figura 4.7: Correlação entre CN e a CN da semana anterior à mesma hora para o período da Primavera




Figura 4.8: Correlação entre CN e a CN da semana anterior à mesma hora para o período do Outono




Figura 4.9: Correlação da CN com a CN de duas semanas anteriores à mesma hora para o período da Primavera




Figura 4.10: Correlação da CN com a CN de duas semanas anteriores à mesma hora para o período do Outono

Tabela 4.1: Valores da correlação entre a CN e a CN da semana anterior e de duas semanas anteriores por período

Período	Inverno	Primavera	Verão	Outono
S1	0,9593	0,9934	0,9768	0,9824
S2	0,9752	0,7545	0,9779	0,9871

Analisando os gráficos das figuras as 4.11, 4.12, 4.13 e 4.14 conclui-se que os diagramas de carga para os diferentes períodos é bastante semelhante ao diagrama de carga com os respetivos atrasos de CN, o que nos comprova ainda mais a afirmação referida anteriormente.




Figura 4.11: Comparação do diagrama de carga semanal com o da semana anterior e duas semanas anteriores para o período de Inverno




Figura 4.12: Comparação do diagrama de carga semanal com o da semana anterior e duas semanas anteriores para o período de Primavera




Figura 4.13: Comparação do diagrama de carga semanal com o da semana anterior e duas semanas anteriores para o período de Verão




Figura 4.14: Comparação do diagrama de carga semanal com o da semana anterior e duas semanas anteriores para o período de Outono

É realizada também a análise da correlação entre a CN de uma e duas semanas antes com uma hora de atraso, ou seja, para a hora 1 do dia 15 de janeiro de 2015, o atraso correspondente será a hora zero do dia 8 de janeiro de 2015 (S1H1) e a hora zero do dia 1 de janeiro de 2015 (S2H1). Para além deste atraso, é efetuada uma outra alteração em que, em vez de uma hora de atraso, passa a duas horas de atraso, (S1H2) e (S2H2). Os resultados obtidos destas correlações encontram-se na tabela 4.2.

Tabela 4.2: Valores da correlação entre a CN e a CN S1H1, S1H2, S2H1 e S2H2 por período

Período	Inverno	Primavera	Verão	Outono
<b>S1H1</b>	0.86	0.88	0.88	0.87
<b>S1H2</b>	0.63	0.65	0.68	0.64
<b>S2H1</b>	0.88	0.64	0.87	0.85
<b>S2H2</b>	0.64	0.46	0.65	0.62

Apesar de apresentar já alguma dispersão na correlação entre a CN e a CN de uma e duas semanas antes com uma hora de atraso, esta ainda se apresenta fortemente correlacionada sendo ainda uma variável justificativa do diagrama de carga, e portanto deve ser levado em conta nas previsões efetuadas. Já as duas horas de atraso apresentaram uma fraca correlação e assim não serão incluídas.

#### 4.3.1.2 Feriados

Em Portugal existem 9 feriados Nacionais, sendo a esta lista são adicionados mais feriados municipais que variam consoante a localidade.

Nos feriados normalmente ocorre o encerramento de indústrias, algum comércio assim como a redução dos transportes públicos. Como referido no ponto anterior, os feriados desta forma afetam o diagrama de carga e a correlação entre as variáveis. Este problema revela extrema importância na previsão de cargas e por isso fazemos um estudo mais aprofundado destes dias “anómalos”

de modo a perceber que influência têm e de que forma afetam o diagrama nos diferentes dias da semana. A figura 4.17 mostra claramente que a carga num feriado baixa significativamente. No entanto também é possível perceber que a carga num fim de semana é também mais baixa, assemelhando-se esta ao comportamento de um domingo. Será então que o impacto causado pelos feriados no diagrama de carga é sempre igual independentemente do dia em que ocorre?




Figura 4.15: Comparação do diagrama de carga da semana de 8 a 14 de Dezembro de 2014 com a semana anterior

Nos feriados a dias úteis o comportamento do diagrama de carga é o correspondente às figuras 4.16, 4.17 e 4.18. É possível perceber que diferentes dias úteis onde ocorre o feriado alteram o diagrama semanal de carga de forma diferente, isto é, o facto de ser em épocas festivas, como é visto na Figura 4.17, época Natalícia, altera o diagrama de carga não só no dia do feriado assim como no dia anterior e posterior. O facto da possibilidade de uma possível “ponte” afeta também o dia anterior ou posterior do diagrama de carga como pode ser visto na figura 4.16 e 4.18.




Figura 4.16: Comparação do diagrama de carga da semana que inclui o feriado de 25 abril 2013 com a semana anterior






Figura 4.17: Comparação do diagrama de carga da época Natalícia com a semana anterior




Figura 4.18: Comparação entre o diagrama de carga da semana de 9 a 15 de Junho de 2014 com a semana anterior

A partir da figura 4.19 depreende-se que caso um feriado ocorra a um domingo, este não terá grande impacto no diagrama de carga. Como já referido o comportamento de um feriado assemelha-se a um domingo, assim para efeitos de previsão de carga estes dias anómalos serão considerados como um domingo, no entanto deve ter tido em especial atenção o dia e época em que ocorrem pois estes influenciam de forma diferente o diagrama de carga.




Figura 4.19: Comparação do diagrama de carga diário feriado de 20 de Abril com o Domingo anterior

#### 4.3.1.3 Temperatura

A temperatura é normalmente assumida como uma variável influente para previsão de carga. Diversos estudos efetuados revelam que a utilização de dados de temperatura permite, melhorar o desempenho da previsão de cargas. No entanto devido a não ser possível dispor dos dados reais de temperatura, apenas de previsões de temperatura, vários artigos defendem que a relação entre dados de consumo e temperatura não seja assim tão clara. A utilização dos dados de temperatura pode ou não ser viável, dependendo do caso específico que se está a analisar, sendo um fator determinante a qualidade dos dados utilizados [36].

A obtenção dos dados da temperatura revelou diversas dificuldades. Em Portugal o histórico de dados não é disponibilizado pelo IPMA, de forma a contornar este problema os dados da temperatura foram retirados de várias fontes, devido a estas não contemplarem toda a informação necessária. De [37], [38] e [39] são retirados dados relativamente a temperatura média diária, temperatura máxima e mínima para algumas localidades. Do SCADA foi retirada a temperatura de quinze em quinze minutos para as restantes localidades, foi efetuado um tratamento desta informação de modo a obter a média diária, máxima e mínima, de forma a que pudessem ser trabalhados os dados de forma coerente e verificado se não existiam dados incorretos nos mesmos. No gráfico da figura 4.20 é possível verificar o que é esperado: temperaturas mais elevadas na época do verão e temperaturas mais baixas na época do inverno, e que a tendência da média Nacional acompanha a temperatura local de Lisboa.




Figura 4.20: Representação da temperatura média diária no ano 2014, para Portugal Continental e para a cidade de Lisboa

As localidades foram seleccionadas por capital de distrito. A obtenção dos dados de temperatura

revelou-se uma grande dificuldade no desenvolvimento desta dissertação e por isso não foi possível obter a temperatura para todas as capitais de distrito. Foram assim selecionados locais próximos, tendo sido selecionados os seguintes:

- Aveiro (valores relativos à cidade Ovar)
- Beja
- Braga (valores relativos ao posto de corte PCCD)
- Bragança
- Castelo Branco
- Coimbra (valores relativos á subestação S40)
- Évora (valores relativos à subestação S2)
- Faro
- Guarda (valores relativos à subestação S20)
- Leiria (valores relativos à vila de Monte Real)
- Lisboa
- Portalegre (valores relativos à subestação S18)
- Porto
- Santarém (valores relativos à subestação S42)
- Setúbal (valores relativos à subestação S51)
- Viana do Castelo
- Vila Real
- Viseu (valores relativos à subestação S3)

A correlação entre a CN e temperatura não apresentou uma forte correlação, No entanto é possível nas figuras 4.21 e 4.22 perceber-se que é notória uma relação entre a temperatura e a CN, isto é, verifica-se que a carga tem tendência a aumentar tanto para temperaturas mais elevadas como para temperaturas mais baixas, estando por isso representada uma “nuvem” mais carregada no gráfico. Foi possível concluir através desta análise que a variável temperatura apresenta uma maior correlação quando é correlacionada com a CN de uma localidade face à correlação com a CN do SEN. Apresenta-se no gráfico da figura 4.23, os valores obtidos de correlação ente a CN e temperatura para algumas localidades e Portugal Continental, é possível perceber-se que a correlação varia entre as várias capitais de distrito, sendo mais relevante para umas, face a outras.




Figura 4.21: Correlação entre valores de temperatura e carga CN para Portugal Continental




Figura 4.22: Correlação entre valores de temperatura e carga CN para cidade de Lisboa




Figura 4.23: Representação da correlação entre a CN por localidade e Portugal Continental com as respectivas temperaturas

## Capítulo 5

# Metodologia de treino das RNA

No presente capítulo é apresentado o plano de trabalho elaborado para obtenção de um modelo de previsão de CN a curto prazo. As várias etapas de pré-processamento são aqui descritas, sendo estas utilizadas para todos os testes realizados no desenvolvimento desta dissertação.

### 5.1 Escolha de Subestações Teste

A REN atualmente possui 63 subestações, onde algumas se encontram em malha fechada. Cada subestação possui as suas próprias características e por isso revelam comportamentos completamente distintos umas das outras.

Através da classificação já referenciada no capítulo anterior, foram escolhidas quatro subestações para realização de testes de modo a obter-se um modelo de previsão eficaz, no entanto no teste final foi necessário a utilização de mais três subestações para uma definição e conclusão mais robusta do melhor método a utilizar. A escolha destas foi feita tendo em conta o tipo de consumo e a sazonalidade, tentando abranger subestações com diferentes tipos de consumos e sazonalidade, assim como alocadas em diferentes distritos, sendo escolhidas para realização de testes a subestação S22, S28, S34 e S45, posteriormente foram selecionadas as subestações S1, S17 e S40.

### 5.2 Metodologia de Trabalho

Traçar uma metodologia de trabalho é um processo fundamental para obter um modelo de previsão eficaz, pois dada a grande quantidade de dados utilizados torna-se impossível obter com sucesso um modelo de previsão eficaz sem estruturar uma metodologia de trabalho e adotar uma forte organização dos dados.

Esta metodologia engloba vários procedimentos necessários, a realização de tratamento e normalização de dados que se depreende como pré-processamento. Após efetuados procedimentos, é possível realizar vários testes para a obtenção do melhor modelo de previsão e por conseguinte a aplicação deste modelo a outras subestações.

Assim é necessário delinear um plano de trabalhos de modo a conseguir obter o resultado final com sucesso, sendo adotado o plano apresentado na figura 5.1. Para além do pré-processamento e treino de redes é necessário uma forte organização dos ficheiros a utilizar de modo a ser possível a obtenção de qualquer dado no decorrer da análise dos casos de estudo.




Figura 5.1: Metodologia global para elaboração de um modelo para previsão de CN

### 5.2.1 Recolha de Dados

A recolha de dados é uma etapa fundamental para o desenvolvimento deste estudo, pois é necessário obter diversos dados históricos de modo a ser possível efetuar vários testes nas redes neuronais, ou seja é necessário disponibilizar um grande conjunto de dados históricos das possíveis variáveis candidatas à rede neuronal, para que esta consiga apresentar resultados satisfatórios da previsão de CN.

Foi necessário obter um histórico de cargas para todas as subestações, conseguido a partir dos registos de telecontagem da REN. Refira-se que estes valores são referentes à carga natural, correspondente à potência média dos registos de energia ativa em (MW), por períodos de 15 minutos, considerando a Produção Distribuída ligada à subestação em causa conforme a topologia típica.

A recolha de dados de temperatura para cada capital de distrito revelou-se uma das grandes dificuldades. Para as subestações dotadas de sensores de temperatura foi possível obtê-la diretamente do SCADA, apresentando registos de temperatura em períodos de 15 minutos em graus Celsius, para as restantes subestações os valores da temperatura foram obtidos através de [37], [38] e [39], apresentando registo da temperatura média, máxima e mínima diária em graus Celsius e Fahrenheit.

O histórico de dados é composto por valores desde Janeiro de 2012 a Dezembro de 2014, contemplando assim um elevado número de amostras, 105216 amostras, de modo a ser possível simular as variações que ocorrem com o decorrer do tempo, sendo este composto pelas seguintes variáveis candidatas entrada da rede neuronal:

- DDS – Dia da semana (1 = domingo; 2 = segunda-feira;...; 7= sábado);
- H – hora de previsão (0, 1,..., 23);
- Fer – Feriados, se sim a variável será 1, caso não se verifique o seu valor será zero;
- FerS1 – Feriado na semana anterior, à mesma hora da hora de previsão
- FerS1H1 - Feriado na semana anterior, uma hora antes da hora de previsão;

- FerS2 – Feriados duas semanas antes, à mesma hora da previsão;
- FerS2H1 – Feriados duas semanas antes, uma hora antes da hora de previsão;
- S1 – Carga na semana anterior, à mesma hora que a previsão;
- s1h1 - Carga na semana anterior, uma hora antes da hora de previsão;
- S2 - Carga duas semanas antes, à mesma hora que a previsão;
- s2h1 - Carga duas semanas antes, uma hora antes da hora de previsão;
- tmax – Temperatura diária máxima;
- tmin – Temperatura diária mínima;
- tmed – Temperatura média diária.

### 5.2.2 Tratamento de Dados

Obtidos todos os dados necessários ao desenvolvimento deste estudo, é deveras importante tratá-los, para que o treino das redes neuronais seja mais eficiente e rápido. Este processo revela-se extremamente moroso e minucioso pois qualquer erro pode ditar um mau resultado final.

Para cada subestação foi criado um ficheiro *Excel*, para posteriormente poderem ser retirados todos os dados necessários à respetiva subestação e caso seja necessária a sua atualização, esta pode ser feita de uma forma rápida. Na figura 5.2 é apresentado um exemplo desta folha.

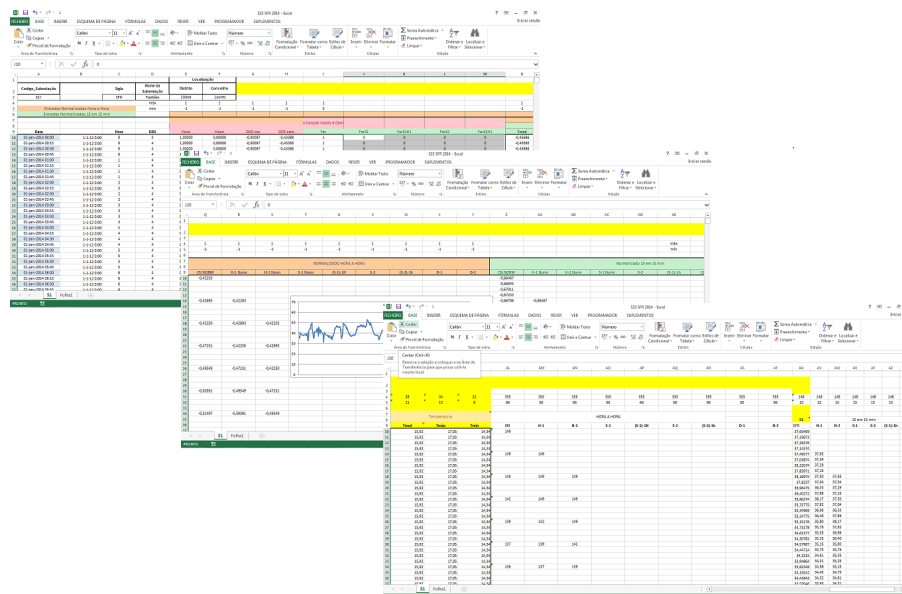


Figura 5.2: Exemplo da folha Excel para tratamento de dados

O tratamento de dados consiste em:

- Verificação dos dados - é efetuada uma verificação a todos os dados de modo a encontrar possíveis erros.

Verificou-se que os valores de CN fornecidos pelo SCADA contemplam a mudança de horário de Verão ou Inverno, aumentando ou diminuindo uma hora para esses dias. Desta forma, é corrigido este problema, para que todos os dias ficassem com 24 horas. Para o horário de Verão são incluídos mais quatro valores na segunda hora do dia, baseados na média da hora anterior e posterior. Para o caso da mudança de horário de Inverno são eliminados os quatro valores referente à segunda hora do dia.

Verificaram-se erros nas temperaturas obtidas pelo SCADA, pois de um período de 15 minutos para outro, a temperatura aumentava ou diminuía (por vezes), cerca de 15 graus Celsius.

- Representação dos dados, consiste na apresentação e conversão dos dados, isto é, a data é transformada em dia da semana, hora e atribuição de uma variável binária para a verificação do dia ser feriado ou não.

Os dados de CN foram obtidos para períodos de 15 minutos. No entanto foi necessário agrupar estes, por períodos de uma hora, para futuros testes a realizar. Para isso é efetuada a soma de quatro períodos de 15 minutos para cada hora.

Devido a diferença entre períodos diários e de 15 minutos para os registos de temperaturas obtidas pelo SCADA foi necessário achar a temperatura máxima e mínima sendo estes valores atribuídos a cada dia.

Conversão da temperatura obtida em Fahrenheit para graus Celsius.

Na tabela 5.1 e 5.2 é apresentado um excerto de possíveis entradas da RNA. F1, F2, F3 e F4 correspondem a FerS1, FerS2, FerS1H1 e FerS2H1 respetivamente.

Tabela 5.1: Representação das possíveis candidatas a variáveis de entrada da RNA, com periodicidade de 15 em 15 min

Data	Hora	DDS	Tmed	Tmáx	Tmin	S1	S2
15-01-2014 01:00	1	4	12,8	14	11	152,9	154,4
15-01-2014 01:15	1	4	12,8	14	11	147,5	152,6
15-01-2014 01:30	1	4	12,8	14	11	143,6	150,3
15-01-2014 01:45	1	4	12,8	14	11	138,9	145,4
S1H1	S2H1	Fer	F1	F2	F3	F4	
174,4	164	0	0	0	1	1	
168,7	160	0	0	0	1	1	
164	159	0	0	0	1	1	
157,9	156	0	0	0	1	1	



Tabela 5.2: Representação das possíveis candidatas a variáveis de entrada da RNA, com periodicidade de uma hora

Data	Hora	DDS	Tmed	Tmáx	Tmin	S1	S2
15-01-2014 01:00	1	4	12,8	14	11	583	603
15-01-2014 02:00	2	4	12,8	14	11	532	546
15-01-2014 03:00	3	4	12,8	14	11	506	496
15-01-2014 04:00	4	4	12,8	14	11	497	464
S1H1	S2H1	Fer	F1	F2	F3	F4	
665	639	0	0	0	1	1	
583	603	0	0	0	1	1	
532	546	0	0	0	1	1	
506	496	0	0	0	1	1	

- Normalização de dados consiste no ajuste de escalas para melhorar a aprendizagem e rapidez do treino da rede. Para normalização da CN e temperaturas foi aplicado o método Min-Máx descrito pela função 5.1, onde o valor  $v$  da escala "a", é convertido num valor  $v'$  da escala "A"[40].

$$v' = \frac{v - \min_a}{\max_a - \min_a} \times (\max_A - \min_A) + \min_A \quad (5.1)$$

Sendo,

$$\min_A = -1,$$

$$\max_A = 1.$$

A normalização da hora e do dia da semana, foi efetuada através das funções 5.2, 5.3 e 5.4, 5.5 respetivamente. Devido a serem variáveis cíclicas, foram transformadas em duas variáveis: seno e cosseno, com o mesmo período, sendo de 24 para a hora e 7 para o dia da semana.

$$Hcos = \cos\left(\frac{2 \times \pi \times H}{24}\right) \quad (5.2)$$

$$Hsen = \sin\left(\frac{2 \times \pi \times H}{24}\right) \quad (5.3)$$

$$DDScos = \cos\left(\frac{2 \times \pi \times H}{7}\right) \quad (5.4)$$

$$DDSsen = \sin\left(\frac{2 \times \pi \times H}{7}\right) \quad (5.5)$$

Onde,

*DDS* – corresponde ao valor do dia da semana do conjunto de entrada;

*H* - corresponde ao valor da hora do conjunto de entrada.

Após a aplicação do processo de normalização à tabela 5.1, surgem os dados normalizados apresentados na tabela 5.3.

Tabela 5.3: Representação das possíveis candidatas a variáveis de entrada da RNA, com periodicidade de 15 em 15 min após normalização

Data	Hcos	Hsen	DDScos	DDSsen	Tmed	Tmáx	Tmín	S1
15-1-14 1:00	0,96593	0,25882	-0,90097	-0,43388	-0,41176	-0,69231	-0,11111	-0,3117
15-1-14 1:15	0,96593	0,25882	-0,90097	-0,43388	-0,41176	-0,69231	-0,11111	-0,36844
15-1-14 1:30	0,96593	0,25882	-0,90097	-0,43388	-0,41176	-0,69231	-0,11111	-0,40987
15-1-14 1:45	0,96593	0,25882	-0,90097	-0,43388	-0,41176	-0,69231	-0,11111	-0,45817
S2	S1H1	S2H1	Fer	F1	F2	F3	F4	
-0,29675	-0,0878	-0,2008	0	0	0	1	1	
-0,3154	-0,1469	-0,2333	0	0	0	1	1	
-0,33957	-0,1963	-0,2505	0	0	0	1	1	
-0,3903	-0,2603	-0,278	0	0	0	1	1	

### 5.2.3 Treino da Rede Neuronal Artificial

Concluído o pré-processamento é possível realizar o treino das redes neuronais, de modo a encontrar-se o melhor modelo para previsão de CN. Definiu-se um conjunto de testes a realizar, representado na figura 5.3, às subestações seleccionadas para teste.

O conjunto de testes apresentado na figura 5.3 tem como objetivos verificar os seguintes aspetos:

- Qual o algoritmo de treino mais eficaz e menos moroso;
- A precisão obtida com variáveis de entrada com periodicidade de 15 minutos ou uma hora;
- A precisão obtida com um histórico de um ano ou três anos;
- A precisão obtida com a inclusão da variável temperatura;
- A precisão obtida com a inclusão da variável feriados;

- A precisão obtida com a inclusão das variáveis temperatura e feriados;
- Qual o melhor número de neurónios a utilizar.

Para a realização dos testes A, B, C e D, foram utilizadas as subestações S22, S28, S34 e S45, para a realização do teste E S1, S17, S22, S34, S40 e S45.

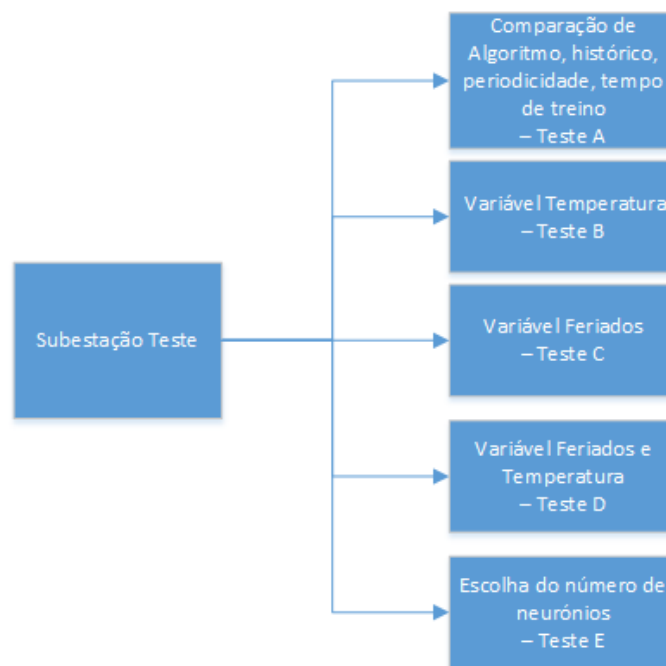


Figura 5.3: Apresentação dos vários testes efetuados

### 5.2.3.1 Comparação de algoritmos - Teste A

Nas RNA existem vários algoritmos de treino que podem ser aplicados para previsão da CN. Após uma longa pesquisa efetuada selecionaram-se dois algoritmos de treino que se demonstraram eficientes e capazes para o desenvolvimento deste estudo: o *Levenberg-Marquardt* e o *Resilient Backpropagation*. De forma a podermos comparar os dois algoritmos, realizamos o teste A para comparação dos algoritmos a nível de precisão da previsão e do tempo de processamento computacional. Para além disto, neste teste é também realizado a comparação de qual o conjunto de dados históricos a utilizar para treino da RNA e a periodicidade das entradas a fornecer à RNA.

Para desenvolvimento deste teste serão realizados para cada subestação 8 subtestes como apresentado na figura 5.4, onde em cada teste são treinadas 5 redes neuronais, ou seja 40 treinos por subestação, perfazendo um total de 160 RNA a ser analisadas.

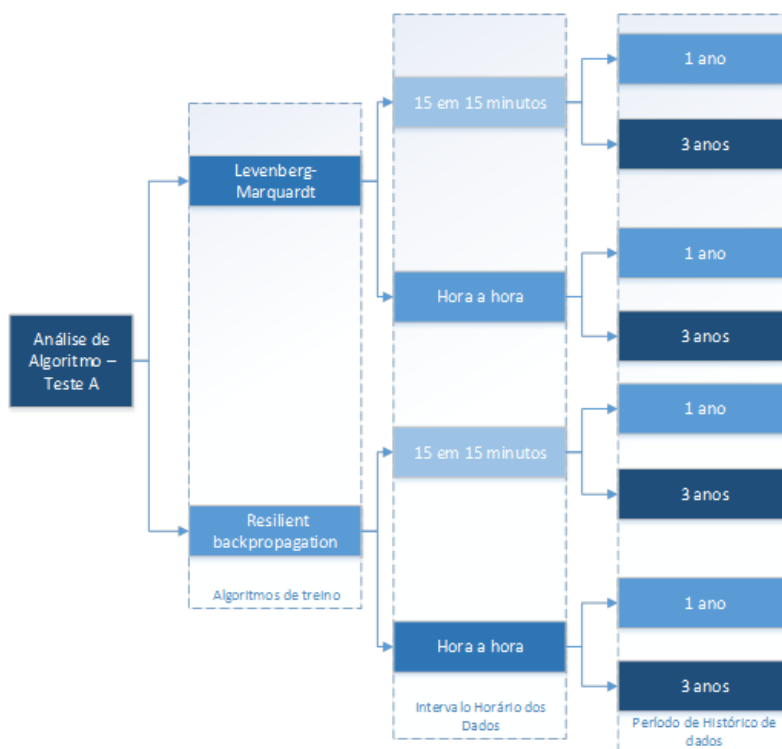


Figura 5.4: Metodologia adotada para desenvolvimento do teste A

### 5.2.3.2 Variável Temperatura - Teste B

A variável temperatura, como já estudado, tem um efeito sobre a CN, pois com o aumento ou diminuição da temperatura a CN varia. Para o estudo da variável temperatura seguiu-se a metodologia apresentada na figura 5.5.

De forma a estudarmos esta variável, realiza-se o teste B, onde é feita a inclusão da variável temperatura. Esta foi dividida em três tipos de temperatura dando origem a 3 novas entradas, que são respetivamente:

- Tmax – Temperatura diária máxima;
- Tmin – Temperatura diária mínima;
- Tmed – Temperatura média diária.

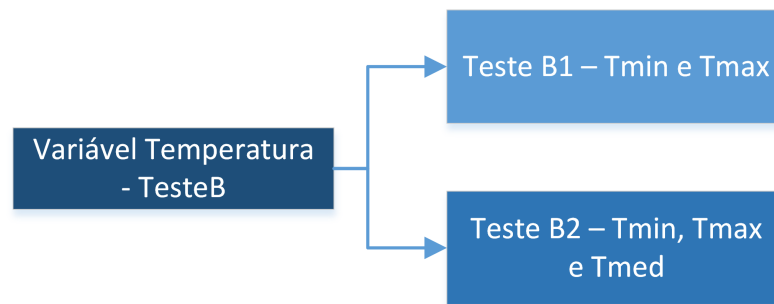


Figura 5.5: Metodologia adotada para desenvolvimento do teste B

O estudo desta variável subdividiu-se em dois testes B1 e B2, onde serão realizados 10 treinos por subestação, o que totaliza um conjunto de 40 RNA a analisar.

### 5.2.3.3 Variável Feriado - Teste C

A CN, como já analisado no capítulo 2, apresenta um comportamento diferente nos dias de feriado, podendo afetar ou não os dias seguintes, isto é, na ocorrência de uma ponte, ou num período festivo. De modo a tentar combater os elevados erros de previsão que se geram nestes dias, é feito um estudo à variável feriado.

A variável feriado deu origem a mais cinco entradas da rede neuronal:

- Fer – Feriados, se sim a variável será 1, caso não se verifique o seu valor será zero;
- FerS1 – Feriado na semana anterior, à mesma hora da hora de previsão
- FerS1H1 - Feriado na semana anterior, uma hora antes da hora de previsão;
- FerS2 – Feriados duas semanas antes, à mesma hora da previsão;
- FerS2H1 – Feriados duas semanas antes, uma hora antes da hora de previsão.




Figura 5.6: Metodologia adotada para desenvolvimento do teste C

A variável feriado deu origem a 2 testes C1 e C2, como é visualizado na figura 5.6, onde no primeiro apenas se indica à RNA que o dia em causa é feriado. Já no teste C2 introduzem-se novas

variáveis de forma a poder-se indicar os feriados anteriores onde a previsão de CN possa depender desses dias. O testes C dará origem a mais 40 RNA.

#### 5.2.3.4 Variável Feriado e Temperatura - Teste D

Após estudado qual o impacto da variável temperatura e feriado, é realizado o teste D para o estudo do efeito da inclusão destas duas variáveis. Este teste é dividido no teste D1 e D2, como indicado na figura 5.7, de forma a perceber-se qual o melhor modelo a aplicar para a previsão da CN. A realização do teste D contempla o treino de dez RNA por subestação, perfazendo um total de 40 RNA a analisar para este teste.

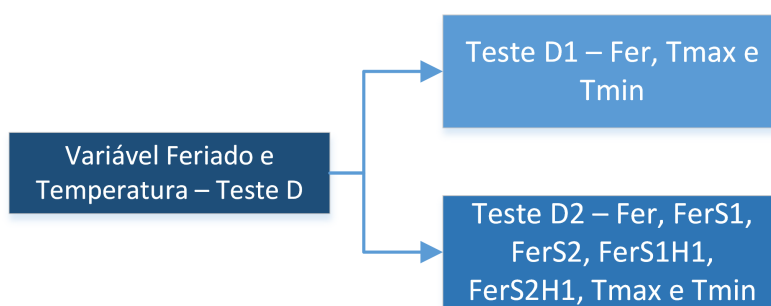


Figura 5.7: Metodologia adotada para desenvolvimento do teste D

#### 5.2.3.5 Número de Neurónios a utilizar - Teste E

Devido a não ser possível obter histórico de dados para outras variáveis que possam influenciar a previsão de CN a curto prazo, após ter-se analisado vários modelos de variáveis de entrada da RNA, é necessário definir qual o número de neurónios a utilizar na camada escondida. É de salientar que todos os testes efetuados anteriormente utilizaram uma RNA com 25 neurónios na camada escondida.

A metodologia seguida para a identificação do melhor número de neurónios a utilizar na camada escondida da RNA é representada na figura 5.8. O teste E consiste em dois subtestes, E1 e E2, onde cada um deles tem duas fases.

A primeira fase corresponde ao aumento do número de neurónios para 30 e 35 e à redução deste número para 20 face o ponto de partida de 25 neurónios. Nesta fase são testadas as subestações S22, S34 e S45.

Na segunda fase, o número de neurónios da camada escondida é progressivamente diminuído para 15, 10, 5 e 2 neurónios. Nesta fase as subestações selecionadas para realização de testes foram S1, S17, S22, S34, S40 e S45. Esta inclusão de mais subestações serviu para uma validação mais conclusiva dos resultados obtidos.

A subestação S28 utilizada nos testes anteriores não foi incluída nestes testes devido a ausência de dados da variável temperatura para o ano de 2015 para a capital de distrito em que esta se insere.

No teste E, para cada subestação teste, serão realizados 40 treinos para cada fase, totalizando um conjunto de 360 treinos. Todos os treinos foram analisados estando os resultados obtidos no capítulo seguinte.

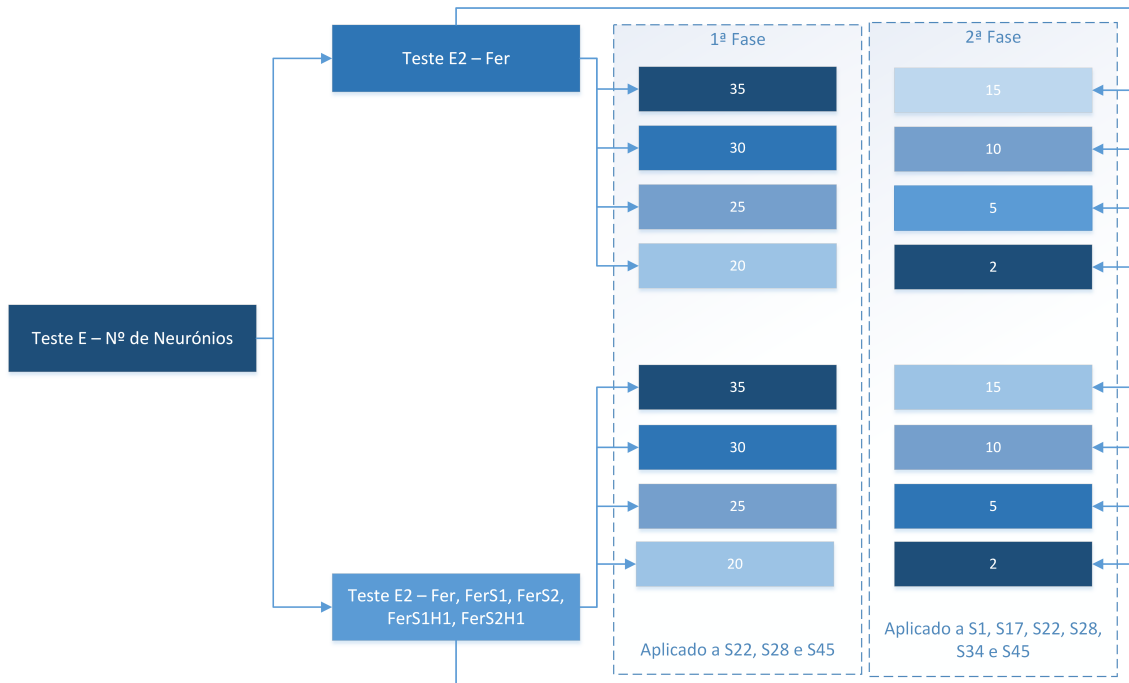


Figura 5.8: Metodologia adotada para desenvolvimento do teste E

### 5.2.3.6 Implementação do Treino da RNA

Para realização dos testes descritos foi utilizado o software *Matlab R2015a*, numa máquina que possui um processador Intel I7 1.6GHz com 6Gb de memória Ram.

Para o desenvolvimento deste procedimento (de modo a ser mais rápido o processamento e a obtenção de resultados), foi adaptado o *script* fornecido pelo NFTOOLS do *Matlab*. Após a elaboração da folha de *Excel* para a respetiva subestação, é possível aplicar o seguinte *script* no *Matlab*, exemplo demonstrado para a subestação S22 [41]:

1. `DDScos = xlsread( 'dados22.xlsx' ,1,'C2:C33693');`
2. `entradas= [ DDScos, ..., Fer];`
3. `saidas=(saida100);`
4. `inputs=entradas';`
5. `targets=saidas';`
6. `hiddenLayerSize = 25;`

```

7. net = fitnet(hiddenLayerSize);
8. net.divideFcn = 'dividerand';
9. net.divideMode = 'sample';
10. net.divideParam.trainRatio = 60/100;
11. net.divideParam.valRatio = 20/100;
12. net.divideParam.testRatio = 20/100;
13. net.trainFcn = 'trainlm';
14. net.performFcn = 'mse';
15. '[net,tr] = train(net,inputs,targets);'
16. outputs = net(inputs);
17. errors = gsubtract(targets,outputs);
18. performance = perform(net,targets,outputs);
19. outputs=transpose(outputs);
20. outputfinal=outputs*100;
21. xlswrite('r225.xlsx',outputfinal,1,'T9');
22. save('redeteste2215.mat','net');

```

O comando 1 importa todo o conjunto de dados presentes na coluna C desde a célula 2 até a 33693, sendo este repetido para as demais entradas alterando a letra da respetiva coluna do *Excel*.

O comando 2 cria a matriz entradas, com as variáveis "DDScos,...,Fer". Caso seja necessário incluir mais variáveis, deve-se adicionar o nome da respetiva variável e retirar, caso seja necessário eliminar a variável.

O comando 3 cria o vetor saídas, com a variável "saida100" já anteriormente importada do *Excel* através do comando 1.

Os comandos 4 e 5 transpõem as matrizes "entradas" e "saida100", e atribui-lhes o nome "inputs" e "targets".

Nos comandos 6 e 7 é criada uma rede neuronal do tipo *feedforward* com 25 neurónios na camada escondida.

Nos comandos de 8 a 12 é feita a divisão aleatória dos dados importados, sendo 60% para treino, 20% para validação e 20% para teste.

No comando 13 é definido o algoritmo de treino utilizado sendo que se utiliza "trainlm" para a utilização de algoritmo de treino *Levenberg-Marquardt* e "trainrp" para o algoritmo de treino *Resilient Backpropagation*.



O comando 14 define o MSE como índice de avaliação do treino; um dos critérios de paragem do treino é se, após seis iterações, o MSE permanecer inalterado, o treino termina. Este é o valor predefinido pelo *Matlab* podendo ser alterado para o número de iterações desejadas.

O comando 15 este comando executa o treino da rede neuronal, tendo como entrada a matriz “inputs” e o “target” como valores alvo para as entradas dadas.

Nos comandos 16 a 18 é efetuada uma previsão através da matriz “inputs”, dando origem ao vetor de previsão “output”. O vetor "output" é transposto e multiplicado por 100 dando origem ao vetor “outputfinal”.

O comando 21 guarda os valores obtidos da previsão num ficheiro Excel. No comando 22 é guardada a rede treinada.

Este *script* foi sendo otimizado de modo a adaptar-se aos testes efetuados, sendo referido aqui apenas um pequeno excerto. Com isto, foi possível automatizar os treinos e tornar o desenvolvimento destes testes menos moroso.

#### 5.2.4 Análise do Desempenho da Rede

É natural que para cada variável introduzida, cada algoritmo utilizado, cada treino efetuado se traduza num resultado diferente de previsão. Sendo esta a principal razão deste estudo, a qualidade da previsão requer uma análise cuidadosa, por forma a obter-se a máxima qualidade.

Para se conseguir uma percepção da qualidade de previsão obtida foram utilizados indicadores de erro que nos permitam uma análise acerca dos resultados obtidos face ao valor real, assim como permitir um termo de comparação entre as diversas redes testadas.

O erro de previsão é obtido pela diferença entre o valor real e o valor da previsão, como demonstrado na expressão 5.6:

$$e_t = A_t - P_t \quad (5.6)$$

Onde,  $e_t$  é o erro no período  $t$ ,  $A_t$  é o valor real no período  $t$  e  $P_t$  é a previsão para o período  $t$ .

#### MAD – Mean Absolute Deviation

O desvio médio absoluto é calculado através da função 5.7, sendo a fração entre o somatório dos desvios absolutos e o número de  $t$  períodos analisados. Define-se como a média dos desvios absolutos entre os valores reais e os valores previstos.

$$MAD = \frac{\sum_{i=1}^t |e_t|}{t} \quad (5.7)$$

### MSE – Mean Squared Error

O erro médio quadrático é um erro a ter em consideração pois as redes neuronais tendem a minimizar o MSE. Este é calculado através da média da soma dos erros de previsão ao quadrado, como demonstrado na expressão 5.8.

$$MSE = \frac{\sum_{i=1}^t e_i^2}{t} \quad (5.8)$$

### MAPE – Mean Absolute Percentage of Error

O erro médio percentual absoluto reflete-se na média em que a previsão se desvia dos valores reais, definindo-se como média da diferença absoluta entre os valores previstos e atuais, expressa em percentagem, calculado como na expressão 5.9.

$$MAPE = \frac{\sum_{i=1}^t \frac{|e_i|}{A_t}}{t} \times 100 \quad (5.9)$$

### RMSE – Relative Mean Squared Error

O erro médio quadrático relativo é um erro que quanto mais próximo estiver de zero, mais precisa será a previsão. Este erro é calculado através da expressão 5.10.

$$RMSE(f) = \frac{MAE(f)}{MSE(\bar{A})} = \frac{\frac{1}{t} \sum_{i=1}^t (A_t - P_t(f))^2}{\frac{1}{t} \sum_{i=1}^t (A_t - \bar{A})^2} \quad (5.10)$$

## Capítulo 6

# Resultados

Neste capítulo são apresentados os resultados obtidos para cada teste efetuado, já referidos no capítulo anterior, assim como as justificações tomadas na evolução da construção do modelo para a RNA de previsão de CN a curto prazo para as subestações da REN. É de salientar que os resultados apresentados correspondem à média obtida dos erros para cada 5 treinos efetuados. Todos os testes efetuados seguiram a metodologia apresentada no capítulo anterior. As subestações selecionadas para o teste A, B, C e D são a S22, a S28, a S34 e a S45 sendo acrescentadas as subestações S1, S17 e S40 para o teste E.

### 6.1 Comparação de Algoritmos - Teste A

Tendo este teste como objetivo a comparação de algoritmos de treino a nível de tempo de processamento computacional, precisão, periodicidade das variáveis de entrada e histórico de dados, foi definida uma rede neuronal simples. Utilizou-se a RNA apresentada na figura 6.1, composta por 8 entradas e 25 neurónios na camada escondida e uma saída.




Figura 6.1: Modelo da RNA utilizada para o teste A

Utilizada a RNA apresentada em 6.1, e seguindo a metodologia apresentada no capítulo anterior obtiveram-se os resultados apresentados nas tabelas 6.1, 6.2, 6.3 e 6.4.

Tabela 6.1: Média dos resultados obtidos por subestação com entradas de periodicidade de 15 minutos, com o algoritmo RPROP

Sub.	Ano	MAD	MSE	MAPE	RMSE	Tempo (min)
S22	2014	13,2	273,3	9,00%	0,596	00:09
	2012/14	12	241	8,40%	0,495	00:59
S28	2014	8,2	168,4	6,10%	0,142	00:14
	2012/14	8,9	157,3	6,60%	0,129	01:25
S34	2014	3,1	21,4	4,90%	0,064	00:20
	2012/14	3,7	39,5	8,70%	0,083	01:19
S45	2014	9,6	156,4	4,10%	0,224	00:17
	2012/14	10,6	195,2	4,60%	0,275	01:25

Tabela 6.2: Média dos resultados obtidos por subestação com entradas de periodicidade de 15 minutos, com o algoritmo LM

Sub.	Ano	MAD	MSE	MAPE	RMSE	Tempo (min)
S22	2014	12,3	239,5	8,40%	0,522	01:14
	2012/14	11,6	223,9	8,00%	0,46	06:43
S28	2014	7,4	137,1	5,50%	0,116	01:43
	2012/14	8,3	165,9	6,20%	0,136	13:25
S34	2014	2,8	17,1	4,40%	0,052	03:08
	2012/14	3,5	34,8	8,10%	0,073	10:31
S45	2014	9	137	3,90%	0,197	01:24
	2012/14	10	172,9	4,30%	0,243	09:51

Tabela 6.3: Média dos resultados obtidos por subestação com entradas de periodicidade de uma hora, com o algoritmo RPROP

Sub.	Ano	MAD	MSE	MAPE	RMSE	Tempo (min)
S22	2014	52,9	4402,9	9,00%	0,609	00:01
	2012/14	48,8	4014	8,50%	0,523	00:05
S28	2014	33,9	2832,1	6,30%	0,15	00:02
	2012/14	35,9	3154,2	6,70%	0,163	00:09
S34	2014	13,1	366,3	5,10%	0,069	00:02
	2012/14	15,2	635,6	9,00%	0,083	00:11
S45	2014	38,6	2543,2	4,20%	0,231	00:02
	2012/14	37,6	2490,1	4,10%	0,222	00:10

A partir das tabelas apresentadas foi possível proceder-se à análise necessária para obter decisões de modo a poderem ser alcançados os objetivos propostos para este teste.

Tabela 6.4: Média dos resultados obtidos por subestação com entradas de periodicidade de uma hora, com o algoritmo LM

Sub.	Ano	MAD	MSE	MAPE	RMSE	Tempo (min)
S22	2014	50,5	4031,2	8,60%	0,558	00:07
	2012/14	47,6	3807,6	8,30%	0,496	00:23
S28	2014	30,6	2375,9	5,70%	0,126	00:05
	2012/14	33,5	2724,1	6,20%	0,141	00:38
S34	2014	11,6	299	4,50%	0,057	00:13
	2012/14	14,2	575,7	8,30%	0,075	00:32
S45	2014	35,9	2217,1	3,90%	0,201	00:09
	2012/14	36,2	2316,9	3,90%	0,206	00:27

### 6.1.1 Comparação de Tempo Computacional

A nível de tempo de computação, os gráficos da figura 6.2 e 6.3, revelam que independentemente da periodicidade das entradas e do seu histórico, o algoritmo LM necessita de um tempo computacional mais elevado.

A utilização de entradas com periodicidade de 15 minutos revela-se muito mais morosa face à introdução de entradas com periodicidade de uma hora, principalmente quando é utilizado um histórico de 3 anos, sendo que a utilização de entradas com periodicidade de uma hora necessita de um tempo computacional menor para treino das RNA.




Figura 6.2: Gráfico referente à média do tempo de treino para entradas com periodicidade de 15 minutos




Figura 6.3: Gráfico referente à média do tempo de treino para entradas com periodicidade de uma hora

### 6.1.2 Comparação de Precisão

Pelos gráficos das figuras 6.4 e 6.5 é possível realizar uma comparação entre o MAPE obtido para cada subestação testada, para um ano e para três anos de histórico alterando a periodicidade das entradas para 15 minutos e uma hora. Aqui verifica-se que o MAPE apresenta sempre um valor inferior para o algoritmo LM. Nas tabelas 6.1, 6.2, 6.3 e 6.4, verifica-se também que todos os erros calculados são inferiores para o algoritmo LM independentemente do tipo periodicidade das entradas da RNA e o histórico de dados para treino. Revela-se então, o LM, o algoritmo mais preciso para este caso de estudo.




Figura 6.4: Gráfico de comparação do MAPE apresentado por cada algoritmo para um histórico de um ano e três anos, com entradas de periodicidade de 15 minutos




Figura 6.5: Gráfico de comparação do MAPE apresentado por cada algoritmo para um histórico de um ano e dois anos, com entradas de periodicidade de uma hora

### 6.1.3 Comparação da Periodicidade das Variáveis de Entrada

Revelando-se o LM o algoritmo mais preciso neste caso de estudo, procede-se ao estudo da periodicidade das entradas da RNA para este algoritmo.

No gráfico da figura 6.6 procede-se à comparação entre a periodicidade das variáveis de entrada para cada subestação teste, para um histórico de dados de um e três anos. Analisando estes resultados conclui-se que o fornecimento de entradas com periodicidade de 15 minutos revela-se mais eficaz, pois apresenta um erro menor para quase todos os casos, exceto para a subestação S45 e S28 para a utilização de um histórico de entradas de 3 anos.




Figura 6.6: Gráfico de comparação da periodicidade de entradas para um histórico de dados de um e três anos.

A diferença entre o erro alcançado para as diferentes periodicidades de entrada é mínimo, no entanto decide-se utilizar uma periodicidade de 15 minutos, dado esta apresentar melhores resulta-

dos e ser mais benéfico para a REN para a programação de indisponibilidade dos transformadores das subestações.

#### 6.1.4 Comparação do Histórico de Dados

A comparação do histórico de dados é realizada para uma periodicidade de entradas de 15 minutos com o algoritmo de treino LM. No gráfico da figura 6.7 é apresentado a comparação entre o MAPE para um e três anos de histórico de dados.




Figura 6.7: Gráfico de comparação do histórico de entradas a utilizar para o algoritmo LM

O MAPE apenas na subestação S22 se verificou um ser pouco mais baixo para um histórico de 3 anos. Já em S28, S34 e S34 revela-se mais baixo para um histórico de dados de um ano, assim como todos os outros erros apresentados na tabelas anteriores. É de notar que na subestação S34 existe uma grande diferença entre o MAPE para um ano e três anos de histórico de dados. De forma a perceber o porquê deste facto nesta subestação, realizou-se um estudo mais pormenorizado. Para isso analisou-se o diagrama de carga anual desta subestação assim como máximos, mínimos e média anual para os anos de 2012, 2013 e 2014.




Figura 6.8: Gráfico de comparação do histórico de entradas a utilizar para o algoritmo LM

Da análise efetuada ao gráfico da figura 6.8 e à tabela 6.5 depreende-se que a CN ao longo dos três anos varia acentuadamente, estabilizando a partir do dia 21 de Julho de 2013. Concluída



Tabela 6.5: Apresentação do valor máximo, mínimo e médio anual de CN para os anos 2012, 2013 e 2014

	CN 2012 (MW)	CN 2013 (MW)	CN 2014 (MW)
<b>Máximo</b>	88,68	110,92	116,48
<b>Mínimo</b>	6,92	13,56	29,92
<b>Média</b>	35,55	43,6	63,66

esta análise efetuou-se um novo teste a esta subestação, composto por mais cinco treinos, com o histórico de dados desde 21 de Julho de 2013 a 31 de Dezembro de 2014. Feita a comparação dos resultados obtidos deste novo teste com os anteriores obtiveram-se os valores de erro apresentados na tabela 6.6.

Tabela 6.6: Comparação de erros entre os 3 testes efetuados para a subestação S34

Data	MAD	MSE	MAPE	RMSE
<b>ANO 2014</b>	2,8	17,1	4,40%	0,051
<b>ANOS 2012 a 2014</b>	3,5	34,8	8,10%	0,072
<b>21/6/2013 A 31/12/2014</b>	3,4	25,1	5,20%	0,071




Figura 6.9: Gráfico de comparação do MAPE para os três testes efetuados para a subestação S34

Por observação da tabela 6.6 e o gráfico da figura 6.9, conclui-se que esta variação de CN entre os três anos estaria a afetar a previsão, pois utilizando o histórico de dados desde a data de estabilização da CN, os erros de previsão baixaram e os resultados obtidos assemelham-se ao comportamento apresentado pelas subestações S28 e S45.

### 6.1.5 Aspetos conclusivos do teste A

Após análise de todos os pontos definidos para o teste A, decidiu-se que apesar de um resultado de previsão mais preciso do algoritmo LM, será utilizado o algoritmo RPROP para o estudo da adição de novas entradas à RNA, devido a este algoritmo apresentar um tempo computacional

reduzido e os seus erros de previsão não terem comprometido o estudo. Para a realização dos testes finais, nomeadamente no teste E, as redes serão treinadas com o algoritmo LM, devido às variáveis de entradas neste teste já estarem definidas e por consequência, ditarem o resultado final deste modelo.

A periodicidade de entradas a utilizar no desenvolvimento da RNA será de 15 minutos. O histórico de dados a utilizar será de um ano, devido ao erro elevado apresentado na subestação S34 (com um histórico de dados de entrada de três anos).

## 6.2 Variável Temperatura - Teste B

Para o estudo da variável temperatura são adicionadas novas variáveis de entrada à RNA do teste A, dando origem a dois novos modelos de RNA. Com a inclusão de "Tmin" e "Tmax" deu origem à RNA correspondente ao teste B1 e com a adição de "Tmin", "Tmax" e "Tmed" deu origem à RNA apresentada na figura 6.10, composta por 10 entradas para o teste B1 e 11 entradas para o teste B2, com 25 neurónios na camada escondida e uma saída.

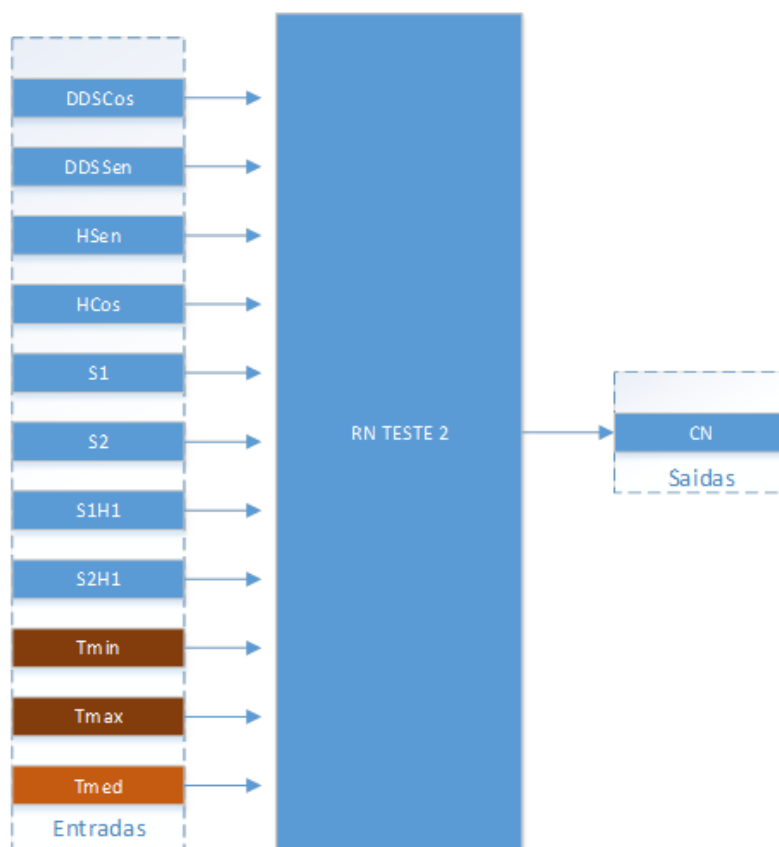


Figura 6.10: Modelo da RNA referente ao teste B2

Aplicando a metodologia anteriormente referida, para se perceber o impacto da variável temperatura na previsão de CN, obtiveram-se os resultados apresentados na tabela 6.7 e no gráfico

## 6.11.

Em comparação com o teste A, os dois testes, B1 e B2, apresentaram uma redução significativa do erro, o que demonstra que a variável temperatura deve integrar a construção do modelo final de previsão.

Os subtestes do teste B, apresentam valores iguais para as subestações S22 e S45. No entanto para as subestações S28 e S34 apresenta um erro MAPE ligeiramente mais baixo para o teste B2. Para uma análise mais detalhada, através da análise da tabela 6.7, verifica-se que o teste B2 atinge erros mais baixos. No entanto esta diferença entre os erros obtidos para o teste B1 e B2 continua a ser mínima.

Devido à obtenção da variável "Tmed" ser de difícil obtenção por parte do REN, e o teste B1 apresentar resultados satisfatórios, é decidido optar por incluir no modelo final de previsão duas variáveis temperatura.

Tabela 6.7: Comparação de erros entre testes

Sub.	Teste B1				Teste B2			
	MAD	MSE	MAPE	RMSE	MAD	MSE	MAPE	RMSE
S22	11,8	220,9	8,00%	0,482	11,7	217,1	8,00%	0,473
S28	7,6	130,1	5,60%	0,11	7,4	123,6	5,40%	0,104
S34	2,6	15,4	4,10%	0,046	2,5	15	4,00%	0,045
S45	8,2	117,4	3,60%	0,168	8,2	117,6	3,60%	0,169




Figura 6.11: Gráfico de comparação do MAPE para os três testes efetuados

## 6.3 Variável Feriado - Teste C

A inclusão da variável feriado, deu origem a duas novas RNA. Estas têm por base a RNA do Teste A, sendo adicionada uma variável binária "Fer", dando origem a RNA do teste C1; e outra com a inclusão de 5 variáveis binárias dando origem a rede neuronal do teste C2, representada na figura 6.12, composta por 13 entradas, 25 neurónios na camada escondida e uma saída.

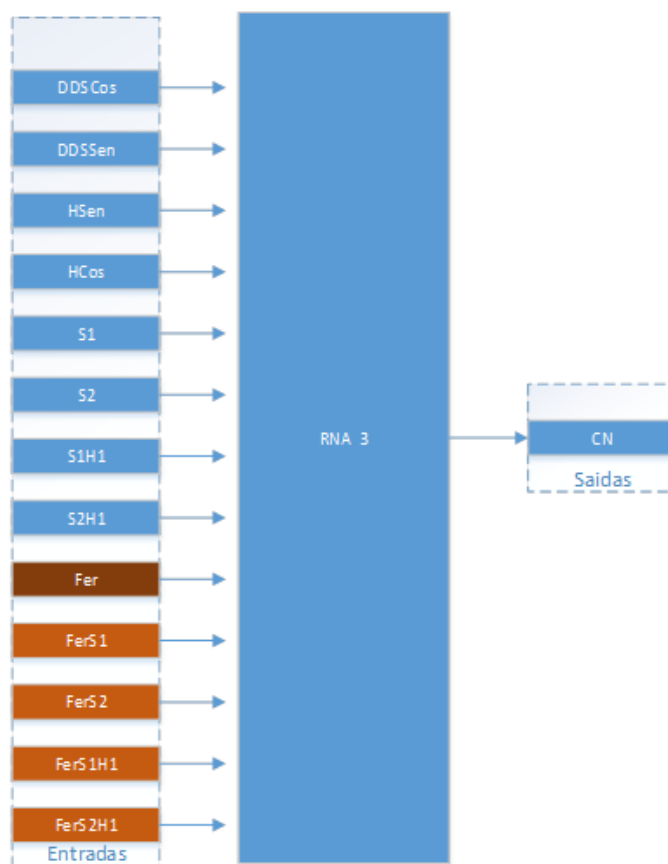


Figura 6.12: Modelos da RNA refente ao teste C2

Neste teste é necessário a análise específica de certos dias de ano, feriados e dias em que a previsão dependa de feriado. Desta forma foi selecionada a semana de 28 de Abril a 4 de Maio de 2014, o feriado de 10 de Junho e o dia 15 de Dezembro de 2014, estando na presente dissertação apresentados os resultados obtidos para a subestação S34.

### 6.3.1 Teste C1

Com a inclusão da nova entrada Fer, teste C1, obtém-se o resultado apresentado nos gráficos da figura 6.13, 6.14 e 6.15.

A semana de 28 de Abril a 4 de Maio de 2014 é uma semana em que a previsão depende de três feriados anteriores, 18, 20 e 25 de abril de 2014 e contempla um feriado, no dia 1 de Maio de 2014.

Na figura 6.13, claramente se percebe que sem a inclusão da variável "Fer" a previsão de CN para o feriado de 1 de Maio de 2014 apresenta um elevado erro. Já a previsão com a introdução da variável feriado, apresenta resultados mais satisfatórios, sendo estes muito mais próximos da CN real. No dia 2 de Maio de 2014, a previsão depende de 2 feriados anteriores e assim a previsão com a introdução da variável "Fer" apresenta erro para várias horas desse dia.




Figura 6.13: Gráfico de comparação entre a CN prevista no teste A, Teste C1 e CN real para S34 na semana de 28 de Abril a 4 de Maio de 2014

Na análise efetuado ao dia 10 de Junho de 2014, é possível constatar a partir do gráfico da figura 6.14, que o modelo reproduzido pelo teste C1 melhora a previsão de CN para o dia de feriado, errando significativamente a partir das 13 horas até as 22 horas.




Figura 6.14: Gráfico de comparação entre a CN prevista no teste A, Teste C1 e CN real para S34 para o dia 10 de Junho de 2014

Como já verificado anteriormente, nos dias em que a previsão depende de feriados anteriores, como no caso do dia 2 de Maio de 2014 o teste C1 errava. No dia 15 de Dezembro de 2014 a previsão de CN também depende de um feriado. Por observação do gráfico da figura 6.15 conclui-se que este modelo C1 não apresenta resultados satisfatórios para estes dias, pois a CN real encontra-se muito superior a partir das 6 horas até cerca das 21 horas deste mesmo dia.




Figura 6.15: Gráfico de comparação entre a CN prevista no teste A, Teste C1 e CN real para S34 para o dia 15 de Dezembro de 2014

### 6.3.2 Teste C2

De modo a colmatar o erro apresentado pelo teste C1 para os dias em que a previsão dependa de feriados, elaborou-se o modelo representado pelo teste C2, onde os resultados obtidos para este, apresentam-se nos gráficos das figuras 6.16 e 6.17. Para o dia 10 de Junho de 2014, o teste C2 apresenta valores previstos mais próximos da CN real, como apresentado no gráfico da figura 6.16.




Figura 6.16: Gráfico de comparação entre a CN prevista no teste A, Teste C1, Teste C2 e CN real para S34 para o dia 10 de Junho de 2014

Por observação do gráfico da figura 6.17, depreende-se que o teste C2 consegue eliminar a falha apresentada pelo teste C1, aproximando extremamente bem a carga prevista para este dia.

Apesar do teste C2 para os dias demonstrados anteriormente apresentar resultados satisfatórios, ao efetuar a análise a outros dias do ano, como o dia 25 de abril e 8 de Dezembro de 2014, apresentado no gráfico da figura 6.18 e 6.19, surgiram dúvidas quanto à escolha do melhor teste.




Figura 6.17: Gráfico de comparação entre a CN prevista no teste A, Teste C1, Teste C2 e CN real para S34 para o dia 15 de Dezembro de 2014




Figura 6.18: Gráfico de comparação entre a CN prevista no teste A, Teste C1, Teste C2 e CN real para S34 para o dia 25 de Abril de 2014




Figura 6.19: Gráfico de comparação entre a CN prevista no teste A, Teste C1, Teste C2 e CN real para S34 para o dia 8 de Dezembro de 2014

### 6.3.3 Comparação dos Testes C1 e C2 com Teste A

Comparando no geral os testes C1, C2 e A, através da tabela 6.8 e do gráfico da figura 6.20, verifica-se que os erros diminuem com a inclusão da variável feriado, o que revela que a introdução desta variável induz a uma melhoria para a previsão de CN.

Tabela 6.8: Comparação de erros obtidos entre os testes C1 e C2

Sub.	Teste C1				teste C2			
	MAD	MSE	MAPE	RMSE	MAD	MSE	MAPE	RMSE
S22	13,07	268,51	8,89%	0,59	12,88	264,7	8,76%	0,58
S28	7,26	119,23	5,28%	0,1	6,86	108,02	4,99%	0,09
S34	2,92	17,19	4,55%	0,05	2,84	16,03	4,43%	0,05
S45	9,44	152,53	4,06%	0,22	9,2	145,14	3,97%	0,21




Figura 6.20: Gráfico de comparação do MAPE para os testes efetuados

A diferença entre os dois testes é mínima, persistindo a dúvida de qual melhor o modelo. Em face destes resultados, foi decidido realizar os próximos testes, utilizando tanto uma, como cinco variáveis feriado.

## 6.4 Variável Feriado e Temperatura - Teste D

Este teste tem como objetivo avaliar o erro com a inclusão das variáveis temperatura e feriado simultaneamente. Não tendo sido o teste C conclusivo quanto à escolha do número de variáveis de feriado a utilizar, este teste subdivide-se no teste D1 e D2.

Neste teste é utilizado o modelo da RNA do teste B1. Pela adição da variável "Fer", surge o teste D1. A inclusão de cinco variáveis feriado dá origem à RNA do teste D2, constituída por 15 entradas, 25 neurónios na camada escondida e uma saída como representa a figura 6.21.

Analisando os resultados obtidos, na tabela 6.9 e no gráfico da figura 6.22, verifica-se que apenas na subestação S45 o MAPE apresenta valores mais elevados para os modelos D1 e D2, no entanto verifica-se que o RMSE e o MSE são mais baixos, o que justifica a utilização deste






Figura 6.21: Modelo da RNA referente ao teste D2

modelo adotado pelo teste D, pois um dos objetivos das redes neurais é minimizar o MSE. O RMSE revela-se melhor quanto mais perto de zero é o respectivo valor, o que também se verifica.

Tabela 6.9: Comparação de erros obtidos para teste D1 e D2

Sub.	Teste D1				Teste D2			
	MAD	MSE	MAPE	RMSE	MAD	MSE	MAPE	RMSE
<b>S22</b>	11,4	205,7	7,80%	0,449	11,2	199,3	7,60%	0,435
<b>S28</b>	2,3	11	3,70%	0,033	2,3	10,3	3,60%	0,031
<b>S34</b>	8,1	114,5	3,50%	0,164	7,9	109,2	3,50%	0,157
<b>S45</b>	6,6	94,1	4,80%	0,079	6,4	90,3	4,70%	0,076

É possível assim concluir-se que a introdução da variável temperatura assim como a introdução da variável feriado no modelo de previsão a curto prazo de CN, se torna fulcral. No entanto a diferença entre o teste D1 e D2 foi novamente mínima. Deste modo não é ainda possível definir-se claramente qual o melhor modelo a utilizar.




Figura 6.22: Comparação do MAPE obtido para todos os testes realizados

## 6.5 Número de Neurónios a Utilizar - Teste E

Encontrados os dois melhores modelos para previsão de CN, neste teste define-se qual o número de neurónios ideal para utilizar na camada escondida da RNA, sendo que é feita sempre uma comparação entre os dois modelos, de forma a podermos encontrar o mais eficaz e preciso.

Seguindo a metodologia descrita no capítulo anterior, e efetuando os testes para a primeira fase, obtêm-se os resultados apresentados na tabela 6.10.

Tabela 6.10: Resultados dos erros obtidos do teste E1 e E2 na primeira fase para as subestações S22, S34 e S45

Sub.	Neurónios	Teste E1				Teste E2			
		MAD	MSE	MAPE	RMSE	MAD	MSE	MAPE	RMSE
S22	20	16,6	468,5	11,30%	0,705	16,8	490	11,50%	0,734
	25	17,9	670,1	12,10%	0,987	19,2	663,9	13,00%	0,994
	30	18,3	615,9	12,50%	0,922	18,2	571,8	12,30%	0,856
	35	18,5	567,7	12,7%	0,856	19,5	695,4	13,20%	0,995
S34	20	4,2	44,5	6,30%	0,113	4,3	40,6	6,40%	0,103
	25	5,1	60	7,60%	0,153	6,1	100,2	9,10%	0,254
	30	6,2	105,9	9,20%	0,269	5,8	77,2	8,70%	0,195
	35	6,1	106,7,2	8,8%	0,270	6,3	120,9	9,40%	0,306
S45	20	10,6	209,5	4,40%	0,238	10,8	207,3	4,50%	0,235
	25	11,3	239,2	4,70%	0,271	12,2	288,6	5,10%	0,327
	30	11,8	270,4	4,90%	0,306	12,6	349,4	5,20%	0,397
	35	13,1	502,7	5,40%	0,57	13,2	339,5	5,50%	0,385

Tendo como ponto de partida os 25 neurónios por indicação da REN, efetuam-se os testes para valores de neurónios acima e abaixo deste valor. A partir da tabela 6.10 constata-se que baixando progressivamente número de neurónios da camada escondida da RNA, os erros melhoram. Já quando o número de neurónios sobe para 35, os erros aumentam, apresentando piores previsões.

Face esta conclusão procede-se à segunda fase do teste E, baixando o número de neurónios da camada escondida da RNA. Após realização dos testes para a segunda fase obtêm-se os resultados apresentados na tabela 6.11.

Pela análise da tabela 6.11, verifica-se que os erros obtidos mais baixos são para 2 e 5 neurónios e estes variam também consoante o número de entradas da RNA.

Tabela 6.11: Resultados dos erros obtidos do teste E1 e E2 na segunda fase para as subestações S1, S17, S22, S34, S40 e S45

Sub.	Neurónios	Teste E1				Teste E2			
		MAD	MSE	MAPE	RMSE	MAD	MSE	MAPE	RMSE
S1	2	7,9	132,5	4,70%	0,084	8,7	198,9	5,30%	0,126
	5	8,6	144,4	5,10%	0,091	8	126,4	4,80%	0,08
	10	8,1	129,1	4,80%	0,082	8,8	157,4	5,20%	0,099
	15	9,1	163,8	5,40%	0,104	9,2	163,4	5,50%	0,103
S17	2	10,2	168	6,90%	0,203	10	160,2	6,70%	0,195
	5	15,6	363,6	10,40%	0,371	14,1	298,5	9,40%	0,32
	10	16,6	422,3	11,00%	0,427	17,3	450,7	11,50%	0,437
	15	25,3	996,1	16,40%	0,917	17,5	502,1	11,70%	0,489
S22	2	14,4	362,6	9,90%	0,548	14,5	364,6	9,90%	0,55
	5	14,5	373,5	9,90%	0,563	15	397,8	10,30%	0,601
	10	15	412,9	10,20%	0,618	15,8	460,7	10,70%	0,686
	15	15,7	431,1	10,70%	0,65	16,6	482,9	11,30%	0,73
S34	2	3,2	22,2	4,90%	0,056	3,3	21,9	4,90%	0,056
	5	3,2	20,4	4,70%	0,052	3,1	19,6	4,60%	0,05
	10	3,5	26,3	5,20%	0,067	3,2	21,9	4,80%	0,056
	15	3,8	33,9	5,70%	0,086	3,7	30	5,60%	0,076
S40	2	7,3	90,6	5,10%	0,117	7,3	89,5	5,10%	0,115
	5	7,8	100,1	5,40%	0,129	7,6	95	5,30%	0,122
	10	8,7	131,1	6,00%	0,169	8,9	129	6,20%	0,166
	15	9,8	171,2	6,80%	0,22	9,5	159,1	6,50%	0,205
S45	2	9,2	161,1	3,90%	0,183	9,7	179	4,10%	0,203
	5	8,9	148,7	3,70%	0,169	8,8	143,2	3,70%	0,163
	10	9,5	163,9	3,90%	0,186	9,5	162,7	4,00%	0,185
	15	10	184,2	4,20%	0,209	9,9	177,4	4,10%	0,201

De modo a poder-se tomar uma decisão na escolha de neurónios e do modelo da RNA a utilizar procede-se à procura dos erros mínimos obtidos por subestação dando origem a tabela 6.12.

É possível concluir, que o teste E2 demonstrou ser mais eficaz, apresentando normalmente um erro menor à exceção da subestação S22. Na subestação S1 o teste E1 apresenta melhores resultados para o MAD e o MAPE. No entanto para o MSE e o RMSE o teste E2 revela melhores resultados.

Tabela 6.12: Identificação do número de neurónios e teste com menor erro por subestação

Sub.	MAD		MSE		MAPE		RMSE	
	Neurónios	Teste	Neurónios	Teste	Neurónios	Teste	Neurónios	Teste
S1	2	E1	5	E2	2	E1	5	E2
S17	2	E2	2	E2	2	E2	2	E2
S22	2	E1	2	E1	2	E1	2	E1
S34	5	E2	5	E2	5	E2	5	E2
S40	2	E2	2	E2	2	E2	2	E2
S45	5	E2	5	E2	5	E2	5	E2

Relativamente ao número de neurónios a utilizar na camada escondida, a decisão foi mais difícil, pois em S17, S22 e S40 os melhores resultados foram obtidos com dois neurónios. Já para S1, S34 e S45 os melhores resultados foram obtidos com 5 neurónios.

De modo a perceber-se qual o melhor número de neurónios a utilizar, seleccionou-se a melhor rede dos 5 treinos efetuados para cada número de neurónios (2 e 5) de cada subestação teste. Posteriormente analisaram-se os erros obtidos para os dias 17 e 22 de Fevereiro de 2015, 3 e 6 de Março de 2015 e 3, 5 e 25 de Abril de 2015. Note-se que os dias seleccionados contemplam feriados e dias úteis aleatórios.

Através da análise dos resultados, obteve-se o seguinte número de neurónios para o melhor erro de MAPE e MSE, para os dias seleccionados por subestação. Estes resultados estão apresentados na tabela 6.13.

A escolha da utilização de 2 ou 5 neurónios na camada escondida revela-se difícil para se poder generalizar para um modelo global. No entanto face os resultados obtidos na tabela 6.13, foi decidido utilizar 5 neurónios na camada escondida.

É assim encontrado o modelo da RNA para previsão de carga natural a curto prazo, com 15 entradas, as utilizadas no teste E2, e 5 neurónios na camada escondida.

Tabela 6.13: Número de neurónios da camada escondida que apresentaram menor erro para os dias seleccionados

Dias	S1	S17	S22	S34	S40	S45
	Neurónios	Neurónios	Neurónios	Neurónios	Neurónios	Neurónios
17-fev	5	5	2	2	2	5
22-fev	5	2	2	5	2	5
06-mar	2	2	2	5	5	5
03-mar	2	5	2	5	2	5
03-abr	5	5	5	5	2	5
05-abr	5	5	2	5	2	5
25-abr	2	2	2	5	2	2

## 6.6 Resultados de outras subestações

De forma a garantir que o modelo do teste E2 é eficaz para previsão de CN, não só para estas subestações teste, mas também para qualquer outra subestação da REN, selecionaram-se mais três subestações da REN, S23, S42 e S53. Esta seleção foi efetuada de acordo com as necessidades da REN.

Às subestações selecionadas é aplicado o modelo E2, para o qual depois de treinadas e testadas para o histórico de dados de 1 de Janeiro a 30 de Abril de 2015, obtiveram-se os resultados apresentados na tabela 6.14:

Tabela 6.14: Resultados obtidos com a aplicação do modelo E2 para outras subestações

SUB.	MAD	MSE	MAPE	RMSE
S23	3,3	19,0	7,9%	0,597
S42	4,9	48,4	6,0%	0,168
S53	5,6	53,4	6,8%	0,236

Através dos resultados obtidos, é possível concluir que o modelo do teste E2 é capaz de prever a CN de forma eficiente, com um erro consideravelmente baixo, apresentando um MAPE máximo de 7.9% para a subestação S23.

## 6.7 Comparação de Resultados com o Modelo de Previsão Desenvolvido

Atualmente o COR dispõe de um modelo de previsão de CN, que se comparou com o modelo desenvolvido na presente dissertação. O período definido para comparação dos respetivos modelos da previsão de CN foi:

- A semana de 20 de Abril a 26 de Abril de 2015. Esta semana contempla um feriado no dia 25 de Abril de 2015.
- A semana de 27 de Abril a 3 de Maio de 2015. Esta semana contém um feriado a 1 de Maio de 2015 e a sua previsão está dependente do feriado de 25 de Abril de 2015.

Na tabela 6.15 são apresentados os resultados obtidos para a previsão da semana de 20 de Abril a 26 de Abril de 2015. Comparando os erros obtidos, conclui-se que todos os erros baixaram com a aplicação do modelo E2. A subestação S23 é a que apresenta uma maior diferença de MAPE, conseguindo este modelo baixar o MAPE em 16,7%, como é apresentado no gráfico da figura 6.23

Através da análise do diagrama de carga semanal da subestação S53, apresentado no gráfico da figura 6.24, verifica-se também que o modelo E2, apresenta melhores resultados para previsão de CN. Um fator também muito importante a sublinhar, é o facto de no dia 25 de Abril de 2015, este novo modelo apresenta resultados mais precisos para a previsão deste feriado.

Tabela 6.15: Resultados obtidos pelo modelo do teste E2 e o modelo de previsão do COR, para a semana de 20 de Abril a 26 de Abril de 2015

Sub.	Modelo E2				Modelo COR			
	MAD	MSE	MAPE	RMSE	MAD	MSE	MAPE	RMSE
S17	11,7	224,3	8,483%	0,661	14,4	377,1	10,3%	0,962
S23	3,7	18,6	9,2%	1,703	10,4	154,0	25,9%	1,801
S42	5,8	64,2	7,4%	0,243	10,4	183,8	13,1%	0,752
S53	4,9	31,2	6,0%	0,213	13,6	258,5	16,7%	1,989




Figura 6.23: Comparação do MAPE para o modelo E2 e o modelo do COR para a semana de 20 de Abril a 26 de Abril de 2015




Figura 6.24: Diagrama de carga real e previsto para a semana de 20 de Abril a 26 de Abril de 2015 para a subestação S53

Na semana de 27 de Abril a 3 de Maio de 2015, o modelo E2 apresentou também resultados mais precisos. Pela análise da tabela 6.16, é possível verificar que o modelo E2 para esta semana apresentou também uma redução em todos os erros. A subestação S23 apresentou a maior redução do MAPE, de 21.6%. Este erro apresenta sempre valores mais baixos com a aplicação do modelo

E2 para todas as subestações comparadas, como reflete o gráfico da figura 6.25.

Tabela 6.16: Comparação do MAPE para o modelo E2 e o modelo do COR para a semana de 27 de Abril a 3 de Maio de 2015

Sub.	Modelo E2				Modelo COR			
	MAD	MSE	MAPE	RMSE	MAD	MSE	MAPE	RMSE
S17	3,3	16,9	3,4%	0,110	13,5	340,1	14,1%	1,281
S23	3,2	13,7	8,0%	1,470	11,8	182,2	29,6%	1,402
S42	7,6	78,7	9,5%	0,347	17,1	641,6	22,7%	1,302
S53	3,3	16,4	3,9%	0,114	16,2	484,4	19,2%	2,313




Figura 6.25: Diagrama de carga real e previsto para a semana de 20 de Abril a 26 de Abril de 2015 para a subestação S53

Pela análise do diagrama de carga previsto para a subestação S17, apresentado na figura 6.26, verifica-se que o modelo de previsão do COR efetua uma previsão errada para o dia 1 e 2 de Maio de 2015, mais uma vez o modelo do COR apresenta um mau resultado de previsão para o dia de feriado. É possível visualizar neste gráfico, que este modelo também erra bastante para o dia 2 de Maio, sendo este dia, um dia em que a previsão depende de um feriado. Ao contrário do atual modelo de previsão do COR, o modelo desenvolvido na presente dissertação, apresentou bons resultados de previsão para ambos os dias.

No anexo C estão apresentados os diagramas de carga semanais para todas as subestações comparadas.

Através da comparação destas duas semanas entre o modelo de previsão do COR e o modelo E2, é possível concluir que o modelo E2 apresenta consistentemente erros de previsão mais baixos, o que significa que consegue melhores previsões de CN a curto prazo, face ao modelo




Figura 6.26: Diagrama de carga real e previsto para a semana de 27 de Abril a 3 de Maio de 2015, para a subestação S17

existente. Dada a eficácia deste modelo, foi desenvolvida a aplicação "Previsão de Carga Natural" apresentada no anexo A, que tem como objetivo auxiliar o COR na programação das indisponibilidade dos transformadores de potência.

### 6.7.1 Perceção do erro obtido

O erro alcançado por este novo modelo de previsão, mostrou uma grande melhoria face aos resultados obtidos pelo atual modelo de previsão do GS, apresentando resultados satisfatórios na previsão de CN a curto prazo. No entanto, como os resultados do novo modelo desenvolvido apresentam ainda alguns erros de previsão é necessário justificá-los, de modo a que o utilizador consiga interpretar melhor os resultados.

Os fatores que afetam a qualidade da previsão alcançada pelo modelo desenvolvido são:

- Como já visto na secção 6.1.4, uma mudança brusca do diagrama de carga de uma determinada subestação, pode afetar os resultados da previsão, pois a rede foi treinada para uma determinada CN, adaptando os seus pesos ao histórico de dados de treino. Caso exista uma modificação acentuada do diagrama de carga a RNA não consegue adaptar-se a essa mudança produzindo resultados imprecisos.
- As transferências de carga entre subestações, resultantes de manobras na rede de distribuição, afetam os dados históricos considerados na previsão. Estas transferências de carga não se realizam sempre nos mesmos períodos e a quantidade de carga transferida não é sempre a mesma. Este facto introduz um aumento de erro para a previsão, nos dias em que isto ocorre.



## Capítulo 7

# Conclusões e Trabalhos Futuros

O presente capítulo tem como finalidade exprimir as principais conclusões retiradas da pesquisa e do estudo realizado no desenvolvimento desta dissertação. São também apresentados possíveis desenvolvimentos futuros, acrescentando uma possível melhoria ao trabalho realizado.

### 7.1 Conclusões

Devido ao aumento da produção em regime especial, o diagrama de carga é fortemente influenciado. A produção distribuída apresenta uma enorme volatilidade, o que faz com que a previsão da potência de transformação seja afetada, podendo causar ao GS dificuldades na programação das indisponibilidades dos transformadores de potência presentes nas subestações MAT/AT da REN. Assim surge o termo carga natural, devido ao trânsito de potências passar a ser bidirecional nos transformadores da REN, traduzindo-se na soma de todos os produtores que se ligam a uma determinada subestação, com o trânsito efetivo nos transformadores de potência.

As subestações MAT/AT foram caracterizadas seguindo uma metodologia desenvolvida, com o objetivo de fornecer ao GS informações quanto ao tipo de consumo e tipo de sazonalidade.

Para desenvolvimento do novo modelo de previsão de CN a curto prazo, foi adotada uma técnica de previsão com Redes Neurais. Esta técnica de previsão depende de variáveis de entrada da RNA. Foi então realizada uma análise sobre as variáveis justificativas do diagrama de carga, e qual a influência que estas têm na previsão de CN.

Os resultados demonstram que a carga natural da semana anterior e a de duas semanas anteriores para a mesma hora, estão fortemente correlacionadas com a carga natural da hora alvo, assim como a carga natural para uma e duas semanas anteriores com uma hora de atraso à hora alvo. Os dias de feriado introduzem uma alteração significativa no diagrama de carga, por isso foi dada especial atenção a estes dias. Concluiu-se que a influência que apresentam no diagrama de carga depende do dia da semana em que este ocorre, e do período festivo em que este se insere. A temperatura não apresentou uma elevada correlação, no entanto foi possível perceber-se que para temperaturas mais elevadas, a CN aumenta, acontecendo o mesmo para as temperaturas mais baixas.

Devido à grande quantidade de dados das variáveis envolvidas, foram desenvolvidas metodologias bem estruturadas para o tratamento dos dados, e para o desenvolvimento dos testes realizados com as RNA, tornando assim os processos menos morosos e facilitando a acessibilidade dos dados. Caso seja necessário realizar um treino para uma nova subestação, ou realizar novos treinos com um novo conjunto de dados, apenas será necessário a introdução dos novos dados e automaticamente serão todos normalizados e agrupados para periodicidades de uma hora e de 15 minutos. No desenvolvimento do novo modelo de previsão foram utilizadas redes neuronais do tipo unidirecional, com os seus neurónios organizados por camadas, *Multilayer Perceptron*, utilizando os algoritmos de treino *Resilient Backpropagation* (RPROP) e *Levenberg-Marquardt* (LM), onde estes dois algoritmos foram objeto de estudo a nível de tempo de computação e precisão. As variáveis de entrada, foram estudadas quanto à sua periodicidade, histórico de dados e influência na previsão de CN a curto prazo. Foi utilizada uma única camada escondida na RNA. Também o número de neurónios a utilizar na camada escondida foi objeto de estudo desta dissertação. Os resultados obtidos revelam que o algoritmo LM é mais preciso face ao RPROP. No entanto necessita de um tempo computacional muito superior. Concluiu-se que para testes de estudo sobre a influência das variáveis, se pode utilizar o algoritmo mais rápido, o RPROP, e para testes finais deve-se aplicar o LM devido a sua precisão. A nível das variáveis de entrada, os resultados demonstram que a utilização de uma periodicidade de 15 minutos e histórico de dados de um ano, é o mais vantajoso.

O novo modelo desenvolvido apresentou resultados muito satisfatórios em comparação com o atual modelo de previsão do GS. O erro de previsão variou de subestação para subestação, no entanto apresentou sempre erros de previsão relativamente baixos e sempre inferiores ao atual modelo utilizado pelo GS. É de salientar que o novo modelo apresenta uma previsão mais precisa em algumas subestações para os dias de feriado, e nos dias em que a previsão dependa de um dia de feriado, o novo modelo desenvolvido apresentou previsões muito mais precisas.

Perante a eficácia de previsão do novo modelo desenvolvido, de forma a auxiliar o GS, foi desenvolvida uma aplicação informática, simples e intuitiva, que forneça de uma forma rápida, a previsão de carga natural ao GS. Assim, este poderá programar as indisponibilidades dos transformadores de uma forma mais segura, visto este modelo apresentar valores próximos à CN real. Esta aplicação foi desenvolvida em *Matlab e Visual Basic*.

## 7.2 Desenvolvimentos Futuros

A previsão de curto prazo utilizando as RNA está sempre em contante mudança, pois novos estudos apresentam novos factos que contribuem para melhorar os modelos desenvolvidos. Diferentes conjuntos de algoritmos e entradas para as RNA, podem ditar melhores resultados. Apesar do modelo proposto nesta dissertação se revelar eficaz, sugere-se para desenvolvimentos futuros alguns pontos que podem ser estudados, para que o modelo de previsão possa ser ainda mais preciso.

Para tal se destaca:

- Desenvolvimento de um método que indique à rede neuronal que ocorreu uma transferência de carga, e quantificar a carga transferida.
- Realizar o treino para todas as subestações. Neste estudo apenas foram criadas redes para 10 subestações num total de 63.
- Efetuar o estudo das variáveis justificativas por subestação, devido ao erro variar de subestação para subestação. Cada rede neuronal deve ser adaptada especificamente para cada subestação.
- Aferir a longevidade de cada rede treinada, para garantir que o erro de previsão se mantém dentro dos valores aceitáveis.
- Realizar um estudo para as subestações que se encontram em malha fechada. Estas devem encarar-se como uma só subestação e posteriormente efetuar-se uma divisão por percentagem de consumo por subestação.



# Referências

- [1] REN - Rede Eléctrica Nacional. Relatório & contas 2014. 2014.
- [2] REN - Rede Eléctrica Nacional. A ENERGIA EÓLICA em portugal 2012. página 3, 2013.
- [3] Vladimiro Miranda. Redes Neurais – treino por retropropagação. 2007.
- [4] Nuno Fidalgo. Redes Neurais - TPRE. 2014.
- [5] Maria Helena, Osório Pestana, e Engenharia Electrotécnica. *Departamento de Engenharia Electrotécnica e de Computadores Avaliação e Controlo de Segurança de Redes Interligadas com Grande Penetração Eólica com base em Métodos de Aprendizagem Automática*. Tese de doutoramento, 2007.
- [6] João Catalão. Previsão dos Preços da Energia Eléctrica através de Redes Neurais Artificiais. 27:151–163, 2007.
- [7] Ricardo Daniel e Silva Machado. *Previsão dos consumos na RNT considerando a produção distribuída – Desenvolvimento de um procedimento de apoio à decisão do Gestor do sistema*. Tese de doutoramento, Feup, 2014.
- [8] Ren - Rede Eléctrica Nacional. REN. URL: [http://www.ren.pt/o\\_que\\_fazemos/eletricidade/o\\_setor\\_eletrico/#5](http://www.ren.pt/o_que_fazemos/eletricidade/o_setor_eletrico/#5).
- [9] Ren - Rede Eléctrica Nacional. acedido em Março de 2015. URL: [http://www.ren.pt/pt-PT/o\\_que\\_fazemos/eletricidade/cadeia\\_de\\_valor\\_da\\_rede\\_de\\_transporte/#4](http://www.ren.pt/pt-PT/o_que_fazemos/eletricidade/cadeia_de_valor_da_rede_de_transporte/#4).
- [10] EDP. acedido em Março de 2015. URL: <http://www.edp.pt/pt/aedp/sectordeenergia/sistemaelectricoportugues/Pages/SistElectNacional.aspx>.
- [11] ERSE. acedido em Março de 2015. URL: <http://www.erse.pt/pt/eletricidade/actividadesdosector/transporte/Paginas/RedeNacionaldeTransporteRNT.aspx>.
- [12] ERSE. acedido em Março de 2015. URL: <http://www.erse.pt/pt/eletricidade/actividadesdosector/transporte/Paginas/RedeNacionaldeTransporteRNT.aspx>.
- [13] Ren - Rede Eléctrica Nacional. Caracterização da rede nacional de transporte para efeitos de acesso à rede. página 72, 2012.
- [14] Ren - Rede Eléctrica Nacional e Eléctrica Nacional. PDIRT - Plano de Desenvolvimento e Investimento da Rede de Transporte de Eletricidade 2014-2023.

- [15] Ren - Rede Eléctrica Nacional. Relatório de Qualidade de Serviço. 2014.
- [16] ERSE. acessado em Março de 2015. URL: <http://www.erse.pt/pt/desempenhoambiental/prodregesp/Paginas/default.aspx>.
- [17] REN - Rede Eléctrica Nacional e Eléctrica Nacional. Missão e Responsabilidades.
- [18] REN - Rede Eléctrica Nacional. Macro Estrutura da Rede Eléctrica. (2), 2013.
- [19] REN - Rede Eléctrica Nacional. GSOR - Operação de Rede.
- [20] S Surender Reddy, Student Member, James A Momoh, e Fellow Ieee. Short Term Electrical Load Forecasting Using Back Propagation Neural Networks. páginas 1–6, 2014.
- [21] a. K. Choobeh. Short Term Load Forecasting for Shiraz Region Using Adaptive Back Propagation Neural Network. *2013 Int. Conf. Commun. Syst. Netw. Technol.*, páginas 583–585, 2013. URL: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6524468>, doi:10.1109/CSNT.2013.125.
- [22] Constantin Barbulescu, Stefan Kilyeni, Attila Simo, Oana Pop, Cosmin Oros, Raluca Schiopu, e Antheia Deacu. ANN techniques for power consumption forecasting. *2013 IEEE Grenoble Conf. PowerTech, POWERTECH 2013*, 2013. doi:10.1109/PTC.2013.6652260.
- [23] Lufuno Marwala. Forecasting electricity demand in South Africa. 2014.
- [24] a Graves, M Liwicki, S Fernandez, R Bertolami, H Bunke, e J Schmidhuber. A Novel Connectionist System for Improved Unconstrained Handwriting Recognition. *IEEE Trans. Pattern Anal. Mach. Intell.*, 31(5):855–868, 2009.
- [25] Ricardo Bessa. *Treino On Line de Redes Neurais com Critérios de Informação Aplicado à Previsão Eólica*. Tese de doutoramento.
- [26] J.P.S. Catalao, S.J.P.S. Mariano, V.M.F. Mendes, e L.a.F.M. Ferreira. An Artificial Neural Network Approach for Short-Term Electricity Prices Forecasting. *2007 Int. Conf. Intell. Syst. Appl. to Power Syst.*, 2007. doi:10.1109/ISAP.2007.4441655.
- [27] S. Valero, J. Aparicio, C. Senabre, M. Ortiz, J. Sancho, e A. Gabaldon. Comparative analysis of self organizing maps vs. multilayer perceptron neural networks for short-term load forecasting. *2010 Mod. Electr. Power Syst.*, (1):1–5, 2010.
- [28] João Ribeiro. Previsão de preços de eletricidade para o mercado MIBEL. 2014.
- [29] D E Castro, Natural Computing, Basic Concepts, C R C Press, Fernando Jos, Von Zuben, Engenharia El, e Universidade Presbiteriana Mackenzie. INTRODUÇÃO ÀS REDES NEURAIS. 2006.
- [30] Claudio Monteiro. Previsão de consumos a curto prazo - Redes Neurais.
- [31] Özgür Ki e Erdal Uncuo. Comparison of Three Back-Propagation Training Algorithm for Two Case Study. 12(October):434–442, 2005.
- [32] Shashank Mishra e G S Tripathi. Comparison of Various Neural Network Algorithms Used for Location Estimation in Wireless Communication. 2(6):2735–2741, 2013.
- [33] Claudio Monteiro. O problema da previsão dos consumos.

- [34] Yong Wang, Dawu Gu, Jianping Xu, e Jing Li. Back propagation neural network for short-term electricity load forecasting with weather features. *Proc. 2009 Int. Conf. Comput. Intell. Nat. Comput. CINC 2009*, (1):58–61, 2009. doi:10.1109/CINC.2009.107.
- [35] F Maciel Barbosa. Gestão Do Diagrama de Cargas. páginas 1–28, 2005.
- [36] J Nuno Fidalgo, Susana Silva, e Manuel Matos. Previsão do diagrama de cargas global do SEN. páginas 1–16, 2007.
- [37] Temperatura. URL: [www.tutiempo.net](http://www.tutiempo.net).
- [38] Temperatura. URL: <http://www7.ncdc.noaa.gov/CD0/cdosubqueryrouter.cmd>.
- [39] Temperatura. URL: <http://www.accuweather.com/pt/pt/portugal-weather>.
- [40] Nuno Fidalgo. Previsão de consumos. 2014.
- [41] MatLab. URL: <http://www.mathworks.com/help/nnet/gs/neural-network-time-series-prediction-and-modeling.html>.
- [42] Matlab. GUI. URL: [http://www.mathworks.com/discovery/matlab-gui.html?s\\_tid=srchtitle](http://www.mathworks.com/discovery/matlab-gui.html?s_tid=srchtitle).
- [43] IPMA. Instituto Português do Mar e da Atmosfera. URL: [www.ipma.pt](http://www.ipma.pt).





## Anexo A

# Aplicação - Previsão de Carga Natural

O desenvolvimento de uma ferramenta de apoio ao GS foi um dos principais objetivos desta dissertação. Após realizado o estudo para a procura do melhor modelo de RNA para previsão de CN a curto prazo, foi possível desenvolver a aplicação “Previsão de Carga Natural”. Esta aplicação foi desenvolvida em *Matlab R2015a* [42], sendo descrito o seu funcionamento no presente anexo, assim como apresentado o manual de utilização.

### A.1 Requisitos da Aplicação

Para ser possível correr esta aplicação é necessário:

- *Matlab* ou compilador *Matlab Comipile Runtime*;
- *Microsoft Excel*;
- Todos os ficheiros devem estar contidos no diretório da Aplicação;
- Ligação à Internet.

### A.2 Comandos da Aplicação

Ao abrir a aplicação “Previsão de Carga Natural”, surgirá no ambiente de trabalho a figura [A.1](#).



Figura A.1: Interface gráfica da aplicação

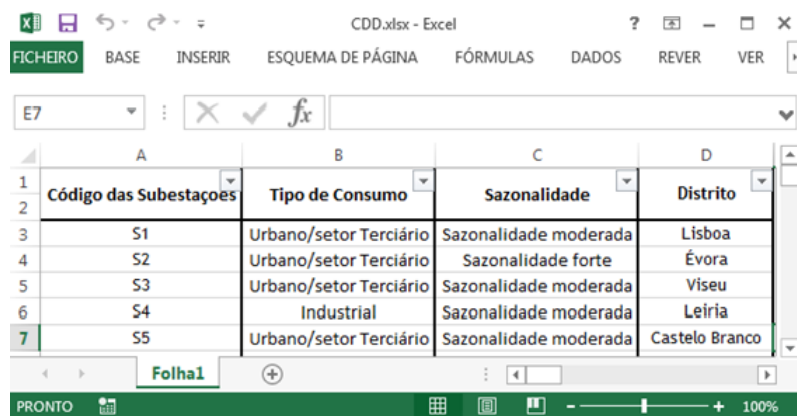
De modo a compreender-se as funcionalidades de cada botão desta aplicação, é apresentada uma breve descrição:

- “1 – Tabela das Subestações” tem como funcionalidade a abertura de um ficheiro Excel, que contém informações referentes às subestações tais como: tipo de consumo, sazonalidade e capital de distrito onde esta se insere.
- “2 – Temperaturas” abre um ficheiro Excel que tem a capacidade de importar as temperaturas máximas e mínimas previstas por o IPMA através do acesso ao site [43].
- “3 – Subestações” disponibiliza a escolha da subestação para a qual pretende fazer a previsão, carrega a RNA treinada para essa subestação e ao mesmo tempo importa a temperatura prevista.
- “4 – Realizar Previsão” realiza a previsão da CN para os próximos 7 dias, surgindo no final da previsão o gráfico referente a essa previsão
- “Previsão” abre um ficheiro Excel onde contém a informação referente à previsão efetuada.
- “Reset” permite ao utilizador apagar toda a informação já carregada, permitindo o começo de uma nova previsão.
- “Ajuda” este botão abre um ficheiro de texto onde contém uma breve ajuda à utilização da aplicação.

## A.3 Manual de Utilização

Para realizar-se uma previsão com sucesso a partir da aplicação “Previsão de Carga Natural” deve seguir os seguintes passos:

1. Clicar no botão 1 para abertura do ficheiro Excel que contém informações relativas a cada subestação, como apresentado na figura A.2;



	A	B	C	D
1				
2	Código das Subestações	Tipo de Consumo	Sazonalidade	Distrito
3	S1	Urbano/setor Terciário	Sazonalidade moderada	Lisboa
4	S2	Urbano/setor Terciário	Sazonalidade forte	Évora
5	S3	Urbano/setor Terciário	Sazonalidade moderada	Viseu
6	S4	Industrial	Sazonalidade moderada	Leiria
7	S5	Urbano/setor Terciário	Sazonalidade moderada	Castelo Branco

Figura A.2: Tabela apresentada pelo botão 1

2. Após saber a informação necessária referente a subestação que deseja realizar a previsão de CN, clique no botão 2. Aqui será aberto um novo ficheiro Excel que nos permite seleccionar a capital de distrito, referente a subestação que desejamos, como apresentado na figura A.3. Após seleccionar a capital de distrito automaticamente receberá a informação das temperaturas máximas e mínimas para os dias em que deseja realizar a sua previsão, como se pode verificar na figura A.4. Feche o ficheiro e selecione a opção guardar;

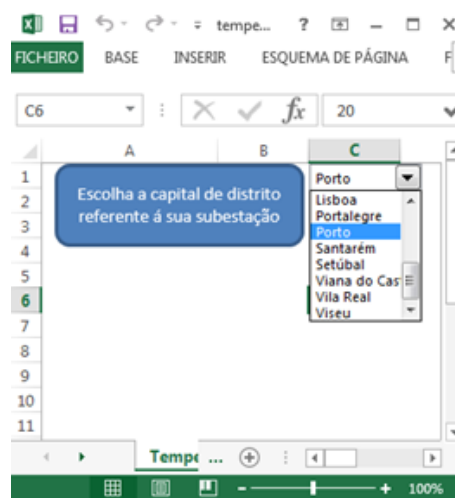


Figura A.3: Ficheiro Excel aberto pelo botão 3

	A	B	C	D	E
1	Cidade	Porto			
2	Data	19-06-2015			
3	min	Máx			
4	20	30			
5	20	31			
6	20	31			
7	20	33			
8	18	27			
9	17	21			
10	14	22			

Figura A.4: Temperaturas apresentadas após a seleção da capital de distrito desejada

3. Clique no botão 3. Aqui é possível a seleção da RNA referente a subestação desejada para previsão de CN. É aberta uma janela como apresenta na figura A.5 para efetuar a seleção e carregar o ficheiro. Após selecionada a subestação, são automaticamente carregadas as temperaturas obtidas anteriormente, preenchendo a tabela temperatura e o nome do ficheiro passa a ter cor verde, como apresentado na figura A.6.




Figura A.5: Janela aberta pelo botão 3 para seleção da subestação desejada



Figura A.6: Interface gráfico da aplicação após ser concluído o processo do botão 3

- Carregue no botão 4. É desencadeado o processo de previsão de CN para os próximos sete dias. Após efetuada a previsão, é apresentado o diagrama de carga referente aos sete dias previstos, como possível visualizar na figura A.7, e os valores previstos são escritos numa folha Excel que é possível ter acesso se carregar no botão “Ver Previsão”.




Figura A.7: Apresentação do gráfico dos valores previstos para a subestação selecionada



## Anexo B

# Caraterização das Subestações

A caraterização das subestações foi feita de acordo com o descrito na presente dissertação.

### B.1 Tipo de Consumo

Os valores de consumo foram obtidos por subestação, para o ano de 2014, a partir dos registos de telecontagem da REN. Refira-se que estes valores são referentes à carga natural, correspondente à potência média dos registos de energia ativa, por períodos de 15 minutos, considerando a Produção Distribuída ligada à subestação em causa, conforme a topologia típica. Os dados foram previamente analisados de modo a eliminar valores anómalos, e foram determinados por estação do ano e por subestação, os valores de carga médios, máximos e mínimos.

Adquiridos estes valores é então possível fazer a caraterização por tipo de consumo, através do fator de carga de cada subestação calculado de acordo com a formula B.1. Para classificar cada subestação de acordo com os três tipos de consumo predominantes, foi necessário escolher os valores limite do fator de carga. De modo a conseguir-se uma classificação coerente, foram analisados vários cenários, incluindo a observação de diagramas de carga das subestações da REN e análise dos esquemas da rede de distribuição, procurando que esta classificação se adequasse à realidade.

$$F_c = \frac{CN_{med}}{CN_{max}} \quad (B.1)$$

Sendo,  $CN_{med}$  a CN média e  $CN_{max}$  a CN máxima (potência ativa) por subestação, dada em MW.

O fator de carga foi obtido através da expressão B.1 e classificado da seguinte forma descrita na tabela B.1:

Na análise dos diagramas de pontas anuais para o tipo de consumo industrial, encontra-se frequentemente uma quebra abrupta no mês de Agosto, o que se depreende pelo facto do período de férias de certas indústrias.

Tabela B.1: Padronização do fator de carga por tipo de consumo

Tipo de Consumo	Fc mínimo	Fc máximo
Rural	0.86	0.87
Urbano/Setor Terciário	0.63	0.64
Industrial	0.88	0.85

## B.2 Sazonalidade

A classificação por sazonalidade foi efetuada a partir dos valores médios, máximos e mínimos por estação do ano de cada subestação, dando origem ao Fator de Carga Sazonal. Se fosse somente efetuada uma análise ao fator de carga por estação do ano para cada subestação, não seria possível uma análise cuidada.

Através do fator de carga não é possível uma classificação correta, isto é, o fator de carga segundo a formula B.1 depende da CN média e da CN máxima. Assim, para uma dada estação do ano Z, a CN máxima apresenta um valor X e um valor de CN média de Y. Para a estação do ano K a CN máxima correspondia a X+1 e a CN média a Y+1. Isto daria exatamente o mesmo fator de carga, no entanto existia uma sazonalidade por estação do ano, que não seria notada através desta análise.

Para ultrapassar esta dificuldade, desenvolveu-se uma metodologia para classificação do fator de carga sazonal, de forma a conseguir-se uma maior dispersão entre os valores da CN máxima e média.

A metodologia de cálculo do fator de carga sazonal seguiu os seguintes passos:

1. Cálculo do Fator de carga sazonal mínimo ( $FC_{Smin}$ ) através da expressão B.2;

$$FC_{Smin} = \frac{Mnimo(CN_{med})}{Mximo(CN_{max})} \quad (B.2)$$

$CN_{med}$  corresponde à CN média por estação do ano e  $CN_{max}$  à CN máxima por estação do ano.

2. Cálculo do fator de carga sazonal máximo ( $FC_{Smax}$ ) através da expressão B.3;

$$FC_{Smax} = \frac{Mximo(CN_{med})}{Mnimo(CN_{max})} \quad (B.3)$$

3. 3. Cálculo do fator de carga sazonal através da expressão B.4.

$$FC_S = FC_{Smax} - FC_{Smin} \quad (B.4)$$



Através do  $F_{CS}$  é possível então obtermos uma maior dispersão de valores e assim classificá-lo da seguinte forma:

Tabela B.2: Padronização do fator de carga sazonal

Sazonalidade	$F_{CS}$ máximo	$F_{CS}$ mínimo
Sem Sazonalidade	0	0,129
Sazonalidade Moderada	0,13	0,29
Sazonalidade Forte	0,3	1

De forma a validar os resultados obtidos, analisaram-se os diagramas de carga mensais para cada subestação, procurando alterações da CN ao longo do ano. Conclui-se que a classificação por  $F_{CS}$  revela-se eficaz, pois das 63 subestações, só 7 delas foram classificadas manualmente. Esta classificação efetuou-se pela observação dos diagramas de carga. As subestações classificadas por análise dos diagramas mensais de carga são: S7, S10, S24, S26, S40, S41 e S44.

Após a classificação é possível na tabela B.3 e no gráfico da figura B.1 verificar os resultados obtidos.

Código das Subestações	Tipo de Consumo	Sazonalidade	Distrito
<b>S1</b>	Urbano/setor Terciário	Sazonalidade moderada	Lisboa
<b>S2</b>	Urbano/setor Terciário	Sazonalidade forte	Évora
<b>S3</b>	Urbano/setor Terciário	Sazonalidade moderada	Viseu
<b>S4</b>	Industrial	Sazonalidade moderada	Leiria
<b>S5</b>	Urbano/setor Terciário	Sazonalidade moderada	Castelo Branco
<b>S6</b>	Urbano/setor Terciário	Sazonalidade forte	Guarda
<b>S7</b>	Industrial	Sazonalidade moderada	Lisboa
<b>S8</b>	Urbano/setor Terciário	Sazonalidade moderada	Lisboa
<b>S9</b>	Urbano/setor Terciário	Sazonalidade forte	Viseu
<b>S10</b>	Industrial	Sazonalidade forte	Porto
<b>S11</b>	Urbano/setor Terciário	Sazonalidade forte	Porto
<b>S12</b>	Rural	Sazonalidade forte	Vila Real
<b>S13</b>	Urbano/setor Terciário	Sazonalidade moderada	Lisboa
<b>S14</b>	Urbano/setor Terciário	Sazonalidade forte	Porto
<b>S15</b>	Industrial	Sazonalidade moderada	Aveiro
<b>S16</b>	Urbano/setor Terciário	Sazonalidade forte	Évora
<b>S17</b>	Urbano/setor Terciário	Sazonalidade moderada	Faro
<b>S18</b>	Urbano/setor Terciário	Sazonalidade moderada	Évora
<b>S19</b>	Urbano/setor Terciário	Sazonalidade forte	Beja
<b>S20</b>	Urbano/setor Terciário	Sazonalidade moderada	Castelo Branco
<b>S21</b>	Urbano/setor Terciário	Sazonalidade forte	Setúbal
<b>S22</b>	Industrial	Sem sazonalidade	Lisboa
<b>S23</b>	Rural	Sazonalidade forte	Portalegre
<b>S24</b>	Urbano/setor Terciário	Sazonalidade forte	Aveiro

<b>Código das Subestações</b>	<b>Tipo de Consumo</b>	<b>Sazonalidade</b>	<b>Distrito</b>
<b>S25</b>	Rural	Sazonalidade moderada	Braga
<b>S26</b>	Industrial	Sem sazonalidade	Braga
<b>S27</b>	Industrial	Sazonalidade moderada	Coimbra
<b>S28</b>	Industrial	Sazonalidade moderada	Aveiro
<b>S29</b>	Urbano/setor Terciário	Sazonalidade forte	Bragança
<b>S30</b>	Rural	Sazonalidade forte	Bragança
<b>S31</b>	Urbano/setor Terciário	Sazonalidade moderada	Viseu
<b>S32</b>	Industrial	Sazonalidade moderada	Santarém
<b>S33</b>	Rural	Sazonalidade forte	Leiria
<b>S34</b>	Urbano/setor Terciário	Sazonalidade forte	Porto
<b>S35</b>	Urbano/setor Terciário	Sazonalidade forte	Braga
<b>S36</b>	Urbano/setor Terciário	Sazonalidade moderada	Aveiro
<b>S37</b>	Urbano/setor Terciário	Sazonalidade forte	Guarda
<b>S38</b>	Rural	Sazonalidade forte	Coimbra
<b>S39</b>	Urbano/setor Terciário	Sazonalidade forte	Faro
<b>S40</b>	Industrial	Sazonalidade forte	Coimbra
<b>S41</b>	Industrial	Sazonalidade moderada	Braga
<b>S42</b>	Industrial	Sazonalidade moderada	Santarém
<b>S43</b>	Urbano/setor Terciário	Sazonalidade forte	Porto
<b>S44</b>	Industrial	Sazonalidade moderada	Braga
<b>S45</b>	Industrial	Sem sazonalidade	Setúbal
<b>S46</b>	Industrial	Sazonalidade moderada	Setúbal
<b>S47</b>	Industrial	Sazonalidade moderada	Santarém
<b>S48</b>	Urbano/setor Terciário	Sazonalidade moderada	Lisboa
<b>S49</b>	Industrial	Sazonalidade moderada	Lisboa
<b>S50</b>	Urbano/setor Terciário	Sazonalidade moderada	Coimbra
<b>S51</b>	Urbano/setor Terciário	Sazonalidade forte	Setúbal
<b>S52</b>	Urbano/setor Terciário	Sazonalidade forte	Lisboa
<b>S53</b>	Urbano/setor Terciário	Sazonalidade forte	Faro
<b>S54</b>	Urbano/setor Terciário	Sazonalidade forte	Porto
<b>S55</b>	Rural	Sazonalidade forte	Faro
<b>S56</b>	Industrial	Sazonalidade moderada	Viseu
<b>S57</b>	Urbano/setor Terciário	Sazonalidade forte	Viseu
<b>S58</b>	Urbano/setor Terciário	Sazonalidade forte	Viana do Castelo
<b>S59</b>	Industrial	Sazonalidade moderada	Porto
<b>S60</b>	Urbano/setor Terciário	Sazonalidade forte	Vila Real
<b>S61</b>	Rural	Sazonalidade forte	Porto
<b>S62</b>	Industrial	Sazonalidade moderada	Lisboa

Código das Subestações	Tipo de Consumo	Sazonalidade	Distrito
S63	Industrial	Sazonalidade moderada	Portalegre

Tabela B.3: Caraterização das subestações




Figura B.1: Gráfico de comparação do tipo de sazonalidade por tipo de consumo



## Anexo C

### Comparação de Métodos




Figura C.1: Diagrama de carga real e previsto para a semana de 20 de Abril a 26 de Abril de 2015 para a subestação S23




Figura C.2: Diagrama de carga real e previsto para a semana de 20 de Abril a 26 de Abril de 2015 para a subestação S42




Figura C.3: Diagrama de carga real e previsto para a semana de 20 de Abril a 26 de Abril de 2015 para a subestação S17




Figura C.4: Diagrama de carga real e previsto para a semana de 27 de Abril a 3 de Maio de 2015, para a subestação S23




Figura C.5: Diagrama de carga real e previsto para a semana de 27 de Abril a 3 de Maio de 2015, para a subestação S42




Figura C.6: Diagrama de carga real e previsto para a semana de 27 de Abril a 3 de Maio de 2015, para a subestação S53





